

Univerzita Karlova

Přírodovědecká fakulta

Studijní program: Geografie

Studijní obor: Geografie a kartografie



Adam Kulich

MONITORING VEGETACE RAŠELINIŠŤ V KRKONOŠÍCH S VYUŽITÍM

DÁLKOVÉHO PRŮZKUMU ZEMĚ

**EARTH OBSERVATION FOR PEAT BOGS VEGETATION MONITORING IN THE KRKONOŠE
MOUNTAINS**

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 Adam Kulich

obor Geografie a kartografie

Název tématu

Monitoring vegetace rašelinišť v Krkonoších s využitím dálkového průzkumu Země

Zásady pro vypracování

Cílem práce bude ve spolupráci se Správou KRNAP vytvořit mapy aktuálního stavu vegetace vybraných mokřadů v Krkonoších, které budou sloužit jako výchozí podklad pro monitoring účinnosti revitalizačních opatření. Pro analýzu budou využita multispektrální data z UAS a trénovací/validační botanická data nasbíraná v terénu. Budou testovány pixelové klasifikační metody maximální věrohodnosti, Random forest a Support vector machine a objektově orientovaný klasifikátor Support vector machine za účelem dosažení maximální přesnosti klasifikace. Bude také provedena srovnávací analýza výsledků jednotlivých klasifikačních metod.

Rozsah grafických prací: 10 stran

Rozsah průvodní zprávy: 60 stran

Seznam odborné literatury:

Alvarez-Vanhard, E., Houet, T., Mony, C., Lecoq, L., & Corpetti, T. (2020): Can UASs fill the gap between in situ surveys and satellites for habitat mapping? *Remote Sensing of Environment*, 243.

Knoth, C., Klein, B., Prinz, T., & Kleinebecker, T. (2013): Unmanned aerial vehicles as innovative remote sensing platforms for high-resolution infrared imagery to support restoration monitoring in cut-over bogs. *Applied Vegetation Science*, 16(3), 509–517.

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.

Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28, 5, 823–870.

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

Konzultant bakalářské práce: x

Datum zadání bakalářské práce: 8.10.2021

Termín odevzdání bakalářské práce: květen 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 8.5.2022

.....

Adam Kulich

Poděkování

Rád bych tímto poděkoval všem, kteří mi v průběhu psaní práce poskytli podklady k vypracování práce nebo odbornou konzultaci. Zejména děkuji vedoucí mé práce doc. RNDr. Lucii Kupkové, Ph.D. za věnovaný čas a odborné vedení práce, za její trpělivost a vstřícnost během konzultací a užitečné rady pro tvorbu práce.

Dále bych rád poděkoval za odborné konzultace ohledně zpracování snímků Ing. Markétě Potůčkové, Ph.D. a za odborné konzultace klasifikačních výstupů Mgr. Vieře Horákové ze Správy KRNAP.

V neposlední řadě patří dík také mé milé a mé rodině za trpělivost a morální podporu.

Monitoring vegetace rašelinišť v Krkonoších s využitím dálkového průzkumu Země

Abstrakt

Cílem práce bylo vytvořit mapy aktuálního vegetačního pokryvu tří krkonošských rašelinišť, které budou využity při monitoringu účinnosti revitalizačních opatření. Pro výzkum byla využita multispektrální obrazová data z UAS a trénovací a validační botanická data, nasbíraná botaniky v terénu. Snímky z bezpilotního UAS DJI Phantom 4 Multispectral byly předzpracovány v softwaru Agisoft Metashape Professional a trénovací a validační data byla dále analyzována a upravena s použitím několika nástrojů pro zvýšení separability. Pro tvorbu map vegetačního pokryvu byly využity pixelové klasifikační metody maximální věrohodnosti, Random forest a Support vector machine a objektivě orientovaná klasifikační metody s klasifikátorem Support vector machine. Klasifikace byly provedeny v softwaru ENVI 5.5 a nejpřesnějších výsledků klasifikace dosáhla objektivě orientovaná metoda, jejíž přesnost se u všech zájmových území pohybovala okolo 96 %, což je lepší výsledek, než najdeme v literatuře. Analýza shody jednotlivých klasifikačních výstupů (prostorový překryv) přinesla různé výsledky pro jednotlivé klasifikátory. U klasifikátorů SVM a RF byl celkový překryv až 76 % (pro oblast Hraniční louky), zatímco pro překryv výstupů SVM a RF byly výsledky horší (mezi 38 a 66 %).

Klíčová slova: klasifikace, UAS, rašeliniště, Krkonošský národní park, vegetace, druhy

Earth observation for peat bogs vegetation monitoring in the Krkonoše mountains

Abstract

Aim of the thesis was to create maps of current vegetation cover of three peat bogs in the Krkonoše mountains, which will be used in monitoring of efficiency of the peat bogs revitalization. The research used Multispectral image data from UAS and training and validation botanical data, collected in the field by botanics. Images from the UAS DJI Phantom 4 Multispectral were preprocessed in Agisoft Metashape Professional software and training and validation samples were further analysed and modified using several tools to increase their separability. The accuracy of the maximum likelihood pixel-based classification methods, Random forest and Support vector machine, and the object-based classification method (Support vector machine classifier), were compared. The classifications were executed in ENVI 5.5 software and the object-oriented method achieved the most accurate classification results, with an accuracy of about 96 % for all three areas, which is better result than what is found in the literature. Analyses of the agreement of the individual classification outputs (spatial overlay) produced different results for each classifier. For the SVM and RF classifiers, the overall overlap was up to 76 % (agreement for area Hraniční louka), while for the overlap of object based classification with SVM and RF outputs, the results were worse (38–66 %).

Key words: classification, UAS, peat bogs, The Krkonoše National park, vegetation, species

Obsah

Seznam obrázků a tabulek.....	9
1 Úvod a cíle práce	11
2 Úvod do problematiky a literární rešerše.....	12
2.1 Klasifikace obrazu	12
2.2 Trénovací stádium řízené klasifikace.....	13
2.3 Klasifikační metody.....	13
2.4 Hodnocení přesnosti klasifikace obrazu	14
2.5 Využití dat z UAS pro studium vegetace.....	15
2.6 Mapování mokřadů s využitím DPZ.....	16
2.7 Použití technologie DPZ v Krkonoších	18
3 Zájmové území	20
3.1 Rašeliniště a mokřady v KRNAPu.....	20
3.2 Hraniční louka.....	21
3.3 Alfrédka	22
3.4 Jakšín	24
4 Použitá data a metodika	25
4.1 Použitá data.....	25
4.2 Klasifikované třídy vegetačního pokryvu.....	26
4.3 Předzpracování dat.....	33
4.4 Analýza dat	36
4.5 Hodnocení přesnosti klasifikací	37
5 Výsledky.....	38
5.1 Maximální věrohodnost	38
5.2 Random forest.....	39
5.3 Support vector machine	41
5.4 Objektově orientovaná klasifikace	43

5.5 Analýza překryvů.....	44
6 Diskuse.....	47
7 Závěr.....	55
Použitá literatura.....	11
Přílohy.....	19

Seznam obrázků a tabulek

Obrázek 1: Zájmové území na mapě KRNAPu	20
Obrázek 2: Hraniční louka, ortomozaika	21
Obrázek 3: Hraniční louka	22
Obrázek 4: Alfrédka, ortomozaika.....	23
Obrázek 5: Alfrédka	23
Obrázek 6: Jakšín, ortomozaika.....	24
Obrázek 7: Jakšín.....	25
Obrázek 8: ukázka snímku z UAS, Hraniční louka.....	26
Obrázek 9: smrk ztepilý (<i>Picea abies</i>).....	27
Obrázek 10: rašeliník (<i>Sphagnum</i> sp.).....	27
Obrázek 11: borovice kleč (<i>Pinus mugo</i>).....	28
Obrázek 12: vlochyň bahenní (<i>Vaccinium uliginosum</i>)	28
Obrázek 13: bezkoleneček modrý (<i>Molinia caerulea</i>)	29
Obrázek 14: brusnice borůvka (<i>Vaccinium myrtillus</i>).....	29
Obrázek 15: třtina chloupkatá (<i>Calamagrostis villosa</i>)	30
Obrázek 16: ostřice bažinná (<i>Carex limosa</i>)	30
Obrázek 17: suchopýr pochvatý (<i>Eriophorum vaginatum</i>)	31
Obrázek 18: ostřice zobánkatá (<i>Carex rostrata</i>).....	31
Obrázek 19: suchopýrek trsnatý (<i>Trichophorum cespitosum</i>).....	32
Obrázek 20: holá organozemě na Hraniční louce	32
Obrázek 21: ukázka artefaktů v severních částech ortomozaiky Hraniční louky	33
Obrázek 22: vadné snímky v severní části Hraniční louky	34
Tabulka 1: Vstupní data pro trénování (validaci) pro lokalitu Hraniční louka	35
Tabulka 2: Vstupní data pro trénování (validaci) pro lokalitu Alfrédka	35
Tabulka 3: Vstupní data pro trénování (validaci) pro lokalitu Jakšín.....	36
Tabulka 4: Hodnocení přesnosti a rozlohy vegetačních tříd na Hraniční louce při klasifikaci metodou MLC	38
Tabulka 5: Hodnocení přesnosti a rozlohy vegetačních tříd na Alfrédce při klasifikaci metodou MLC	39
Tabulka 6: Hodnocení přesnosti a rozlohy vegetačních tříd na Jakšíně při klasifikaci metodou MLC	39
Tabulka 7: Hodnocení přesnosti a rozlohy vegetačních tříd na Hraniční louce při klasifikaci metodou RF	40
Tabulka 8: Hodnocení přesnosti a rozlohy vegetačních tříd na Alfrédce při klasifikaci metodou RF.....	40
Tabulka 9: Hodnocení přesnosti a rozlohy vegetačních tříd na Jakšíně při klasifikaci metodou RF.....	41
Tabulka 10: Hodnocení přesnosti a rozlohy vegetačních tříd na Hraniční louce při klasifikaci metodou SVM.....	41

Tabulka 11: Hodnocení přesnosti a rozlohy vegetačních tříd na Alfrédce při klasifikaci metodou SVM	42
Tabulka 12: Hodnocení přesnosti a rozlohy vegetačních tříd na Jakšíně při klasifikaci metodou SVM	42
Tabulka 13: Hodnocení přesnosti a rozlohy vegetačních tříd na Hraniční louce při klasifikaci metodou OBIA (scale level 50, merge level 90)	43
Tabulka 14: Hodnocení přesnosti a rozlohy vegetačních tříd na Alfrédce při klasifikaci metodou OBIA (scale level 20, merge level 60).....	44
Tabulka 15: Hodnocení přesnosti a rozlohy vegetačních tříd na Jakšíně při klasifikaci metodou OBIA.....	44
Tabulka 16: Shrnující tabulka shod překryvů mapových výstupů jednotlivých klasifikačních metod	45
Tabulka 17: Srovnání přesnosti několika výzkumů v porovnání s touto prací	53

1 Úvod a cíle práce

Práce se zabývá mapováním vegetačního pokryvu vybraných rašelinišť v západních Krkonoších s využitím dálkového průzkumu Země (DPZ). Konkrétně se jedná o botanicky cenné lokality Hraniční louka, Alfrédka a Jakšín. Hlavním cílem práce je zmapovat aktuální složení vegetace v úrovni jednotlivých druhů. Aktuální mapování je důležité proto, že zachytí stav dlouhodobě poškozených rašelinišť před plánovanou revitalizací. V průběhu příštích let poslouží aktuální mapa jako výchozí podklad pro monitoring změn druhového složení a prostorového rozložení vegetace, k nimž dojde v důsledku revitalizačních opatření. Pro analýzu budou využita multispektrální data z UAS a trénovací/validační botanická data nasbíraná v terénu. Budou testovány různé metody klasifikace s cílem dosažení maximální přesnosti.

Monitoring druhového složení rašelinišť pomáhá lepšímu porozumění jejich dynamice a účinnosti revitalizačních opatření, což přispěje k optimalizaci jejich ochrany. Ochrana rašelinišť je důležitá pro zachování jejich základních funkcí v ekosystému, mezi něž patří čištění znečištěných vod, prevence záplav, obnova zásob podzemní vody, ale také důležitá funkce v uhlíkovém cyklu. Rašeliniště jsou také přirozeným prostředím pro velké množství živočišných i rostlinných druhů. Jsou však i křehkým biotopem a jejich celosvětová plocha byla lidskou činností zredukována přibližně o polovinu (Fraser & Keddy, 2005), takže ochrana je velmi potřebná.

Dálkový průzkum Země (DPZ) je v mapování vegetace, včetně rašelinišť, velmi efektivním nástrojem, disponujícím proti terénním průzkumům především větší flexibilitou a nižší časovou a finanční náročností. Tyto výhody nabývají ještě většího významu při práci s UAS (Unmanned Aircraft Systems), které jsou schopné poskytnout snímky zemského povrchu s velmi vysokým prostorovým rozlišením a na jejichž základě je možné s pomocí metod DPZ, především klasifikace obrazu, mapovat vegetaci rašelinišť i na úrovni druhů (Alvarez-Vanhard et al., 2020). Tato práce využívá technologie DPZ a zkoumá jejich výhody a limity při mapování tří zájmových území v Krkonošském národním parku, který je jedním z nejcennějších chráněných území v Česku.

2 Úvod do problematiky a literární rešerše

2.1 Klasifikace obrazu

Základní analytickou metodou užitou v práci je klasifikace obrazu. Tato metoda využívá radiometrických charakteristik obrazových dat k přiřazení jednotlivých pixelů do homogenních tříd. Způsobů klasifikace existuje velké množství a jsou definovány především vlastním klasifikačním algoritmem (klasifikátorem), který analyzuje a třídí pixely. Klasifikátor může členit objekty do tříd nejen na základě spektrálních charakteristik (příznaků), ale také na základě texturálních či tvarových příznaků, prostorových vztahů nebo časového chování (Canada Centre for Mapping and Earth Observation, 2016; Dobrovolný, 1998)

Podle způsobu, jakým zasahuje zpracovatel do klasifikačního procesu, lze dělit klasifikaci na řízenou a neřízenou. Při řízené klasifikaci vybírá zpracovatel předem třídy, do kterých chce pixely obrazu roztrdit, a definuje je výběrem tzv. trénovacích ploch (Kolář et al., 2000). Klasifikační algoritmus porovná každý obrazový prvek s trénovacími plochami všech tříd a určí, do které z nich spadá. Trénovací plochy musí být vybrány tak, aby byla zaručena správnost jejich určení, a to z terénu nebo přímo z obrazových dat. Neřízená klasifikace naopak trénovací plochy pro svůj výpočet nepotřebuje a rozřadí obrazové prvky do spektrálních tříd na základě jejich tendence tvořit shluky v příznakovém prostoru. Poté může zpracovatel podle potřeby sloučit vzniklé třídy a přidat jim informační obsah (Dobrovolný, 1998).

Pokud při klasifikačním procesu přiřazujeme k třídám jednotlivé pixely, jedná se o pixelovou klasifikaci. Jiné přístupy ke klasifikaci mohou do klasifikačního procesu zařadit také prostorový vztah k okolním pixelům a rozhodovat i na základě podobnosti blízkých pixelů nebo opakování podobných hodnot. Oba tyto přístupy kombinuje objektivně orientovaná klasifikace (OBIA), která nejprve segmentuje obraz na větší objekty, které následně klasifikátor rozřazuje do tříd (Lillesand et al., 2015).

Výběr vhodné klasifikační metody je zásadním předpokladem úspěšné klasifikace (Lu & Weng, 2007). Proto se tato práce soustředí na výběr klasifikačních metod a porovnání jejich úspěšnosti. Jelikož jsme měli pro zájmová území k dispozici trénovací/validační data pořízená v terénu, byly použity pouze metody řízené klasifikace, a to konkrétně metoda maximální věrohodnosti (MLC – maximum likelihood classification), metoda Random forest (RF), Support vector machine (SVM) a také OBIA s využitím klasifikátoru SVM. Dále se tedy bude práce věnovat především řízené klasifikaci.

2.2 Trénovací stádium řízené klasifikace

Vedle správně zvolené klasifikační metody je kvalita a množství dat zahrnutých do trénovacího procesu jedním z určujících parametrů pro kvalitu výsledku klasifikace (Lillesand et al., 2015; Lu & Weng, 2007). Podle Hixson et al. (1980) je dokonce správný výběr trénovacích vzorků důležitější než výběr samotného klasifikátoru. Dobrovolný (1998) a Kolář et al. (2000) se shodují na tom, že trénovací data musí být pro dobrý výsledek především kompletní a reprezentativní. Měla by tedy zahrnovat všechny spektrální třídy, vyskytující se v obraze, a vhodným způsobem zahrnovat typické spektrální i prostorové vlastnosti těchto tříd. Proto je třeba, aby byly trénovací plochy dostatečně velké a vhodně umístěné. Další nutná vlastnost trénovacích ploch je dostatečná homogenita spektrálních charakteristik pixelů uvnitř třídy a dostatečná heterogenita mezi třídami. Kvalitu trénovacích množin lze ohodnotit například s využitím měř variability pixelů jako rozptyl nebo směrodatná odchylka (Dobrovolný, 1998).

Pro hlubší analýzu kvality trénovacích ploch lze využít několik nástrojů, které mohou pomoci otestovat kvalitu trénovacího datasetu. Základním zobrazením spektrálních charakteristik vybrané plochy v jednom pásmu je histogram. S jeho pomocí můžeme například odlišit inkonzistence uvnitř tříd a následně rozhodnout o rozdělení do více tříd (Kolář et al., 2000). Pro srovnání spektrálních charakteristik dvou a více tříd slouží rozptylogram (scatterplot), který porovnává naměřené hodnoty každého pixelu ve dvou až třech pásmech. Tyto informace lze využít ke zpřesnění trénovacích ploch a tím výsledků klasifikace (Amani & Mobasheri, 2015). Míru separace tříd (separabilita) v příznakovém prostoru, kterou rozptylogram demonstruje, lze vyjádřit i číselnými parametry. Mezi nejvýznamnější míry separability patří např. index separability (SI), statistická divergence nebo Jeffriesova-Matusitova vzdálenost. S pomocí těchto metrik lze porovnat trénovací plochy a do určité míry je upravit, například odebrat překrývající se vzorky. Je však zároveň třeba opatrnosti, aby z dat nebyly odebrány důležité informace (Liu et al., 2020; Mthembu & Marwala, 2008; Richards & Jia, 2006; Schmidt & Skidmore, 2003).

2.3 Klasifikační metody

2.3.1 Klasifikátor maximální věrohodnosti

První klasifikační metoda užitá v této práci je klasifikátor maximální věrohodnosti (maximum likelihood, MLC), která je nejběžnější a nejvíce používanou metodou pro řízené klasifikace obrazových dat (Richards & Jia, 2006; Sohn & Rebello, 2002; Xu et al., 2005). Jeho principem je statistický výpočet pravděpodobnosti že každý pixel náleží do každé třídy, a porovnání těchto pravděpodobností. Patří mezi parametrické klasifikátory, které předpokládají, že četnosti naměřených hodnot v jednotlivých třídách mají normální (Gaussovo) rozdělení (Kolář et al., 2000). Tato vlastnost je hlavní nevýhodou tohoto klasifikátoru, protože i když v běžných obrazových datech jde o rozumný předpoklad (Lillesand

et al., 2015), ve složitém obrazu, který vzniká snímkováním komplexní krajiny, není vždy naplněn (Xie et al., 2008). Proti komplexnějším klasifikátorům je také nevýhodou, že není možné do rozhodovacího procesu zahrnout i jiné než spektrální a statistické příznaky (Lu & Weng, 2007).

2.3.2 Klasifikátor random forest

Random forest (RF) je klasifikační metoda, patřící mezi algoritmy strojového učení, založená na principu rozhodovacího stromu což je automaticky utvořený systém jednoduchých pravidel, určený k rozřazování pixelů do jednotlivých tříd. Algoritmus RF vytvoří velké množství rozhodovacích stromů, založených na náhodně vybraných vektorech. Při aplikaci na obrazová data je vybrána třída, do níž rozhodovací stromy pixel nejčastěji zařadí (Breiman, 2001). Tato klasifikační metoda se v DPZ při klasifikaci krajinného pokryvu velmi často, a to díky své schopnosti pracovat s velmi komplexními daty (Belgiu & Drágu, 2016; Liu et al., 2020; Nitze et al., 2015). Jeho dalšími výhodami jsou poměrně rychlá trénovací fáze, necitlivost na šum v datech nebo také vysoká přesnost (Belgiu & Drágu, 2016).

2.3.3 Klasifikátor support vector machine

Support vector machine (SVM) je algoritmus strojového učení, který je v posledních letech stále častěji používán v klasifikaci krajinného pokryvu (Mountrakis et al., 2011). Klasifikátor používá optimalizační algoritmy k nalezení hranice mezi každou dvojicí tříd v příznakovém prostoru a následně podle těchto hranic rozhoduje, do které třídy bude pixel zařazen (Huang et al., 2002). Dosahuje velmi dobrých výsledků, lepších než většina klasických starších metod (Kupková et al., 2017; Liu et al., 2018; Marcinkowska et al., 2014), a funguje dobře i na malé vzorky trénovacích dat a na komplexních datech (Pal & Mather, 2005).

2.3.4 Objektově orientované klasifikátory (OBIA)

Tento typ klasifikátoru využívá toho, že při klasifikaci obrazových dat s vysokým prostorovým rozlišením často výrazně lépe reprezentují strukturu povrchu skupiny pixelů než samostatné pixely (Blaschke, 2010; Yu et al., 2006). Na rozdíl od výše zmiňovaných pixelových klasifikátorů, objektový klasifikátor pracuje ve dvou fázích. První fází je segmentace, tedy rozdělení obrazu do spektrálně homogenních skupin pixelů (segmentů/objektů), a druhá fáze je samotná klasifikace těchto objektů některou z dalších klasifikačních metod (Meneguzzo et al., 2013). OBIA se často využívá při klasifikaci krajinného pokryvu na snímcích s vysokým prostorovým rozlišením a dosahuje velmi dobrých výsledků, často srovnatelných s náročnějšími metodami pracujícími s jednotlivými pixely, nebo dokonce lepších (Cao et al., 2018; Du et al., 2021; Duro et al., 2012; Fu et al., 2021; Meng et al., 2017; Yu et al., 2006).

2.4 Hodnocení přesnosti klasifikace obrazu

Hodnocení přesnosti klasifikace je proces, který se pokouší odpovědět na otázku na jakém podílu plochy zájmového území odpovídá klasifikovaná třída skutečnosti (Olofsson et al., 2014). Analýza

přesnosti klasifikovaného obrazu využívá tzv. validačních ploch. Ty jsou v ideálním případě, stejně jako trénovací plochy, nasbírány v terénu (pomocí přesné GPS) (Dobrovolný, 1998). Nejpoužívanější metodou hodnocení přesnosti klasifikací je chybová matice, která je zároveň jádrem dalších složitějších postupů použitých v literatuře. Jedná se o jednoduchou tabulku, shrnující počty validačních pixelů v jednotlivých třídách a jejich zařazení klasifikátorem. S použitím této matice lze nalézt nejčastější chybné výsledky a nepřesnosti mezi třídami, které mohou být v dalších klasifikacích opraveny s použitím přidané rozlišující informace (Foody, 2002). Z chybové matice lze vyvodit celkovou průměrnou přesnost, ale i uživatelskou a zpracovatelskou přesnost pro jednotlivé třídy. Kromě celkové přesnosti se pro číselné hodnocení přesnosti klasifikace často využívá také tzv. kappa index, který porovnává klasifikaci s čistě náhodným rozdělením pixelů do tříd (Dobrovolný, 1998). Podle některých autorů však tento index není vhodný k vyjádření celkové přesnosti klasifikace (Foody, 2020).

2.5 Využití dat z UAS pro studium vegetace

Intenzita používání bezpilotních letounů (Unmanned Aircraft Systems; UAS) v DPZ, stejně jako v jiných oborech, v posledních několika letech výrazně roste (Shakhatreh et al., 2019). Při studiu druhového složení porostu a dalších podrobných analýzách ve velkém detailu nemusí být satelitní a letecké snímky uspokojivým zdrojem dat, zejména kvůli nízkému prostorovému nebo spektrálnímu rozlišení, finanční nákladnosti a časté nutnosti pracovat s daty z konkrétního časového období (Alvarez-Vanhard et al., 2020; Anderson & Gaston, 2013). Snímkování z UAS dnes dokáže produkovat multispektrální i hyperspektrální obrazová data s prostorovým rozlišením v řádech centimetrů, která jsou velmi užitečná při studiu vegetace i dalších druhů krajinného pokryvu. Důležitou částí práce s UAS je následné zpracování obrazu, které pomáhá automatizovat řada softwarů (Colomina & Molina, 2014). Mezi hlavní limitace práce s UAS patří malá nosnost, výdrž baterií a dolet a také citlivost na povětrnostní podmínky. Použití UAS je tedy většinou omezeno na území o relativně malé rozloze (Matese et al., 2015; Nex & Remondino, 2014).

Využití UAS ve výzkumu vegetačního pokryvu je poměrně novým a rychle se rozvíjejícím přístupem v DPZ. Nesporné výhody využití UAS se projevují zejména při zkoumání oblastí, které jsou špatně dostupné pro pozemní průzkum (např. mangrovové porosty) nebo míst, kterým hrozí poškození při neopatrném pozemním sběru dat (například rašeliniště). UAS se ale pro svou flexibilitu používá i v jiných habitatech i pro lesnické nebo zemědělské účely. V průzkumu stavu životního prostředí se také tyto technologie často používají při zkoumání kvality nebo charakteru půdy (Manfreda et al., 2018). Používání UAS má při studiu vegetace proti pozemnímu mapování i své nevýhody, jako například neschopnost snímat nižší patra vegetace mezi dřevinami. Tento problém se řeší snahou o optimalizaci letové výšky UAS (Cruzan et al., 2016).

V literatuře použili pro tvorbu map vegetačního pokryvu snímkování UAS například Lu & He (2017), kteří s pomocí OBIA porovnávali stav travních porostů v Ontariu (Kanada) v různých fázích vegetační sezóny. Hung et al. (2014) použili UAS snímkování k testování přesnosti vlastního klasifikačního algoritmu, se kterým mapovali invazní druhy v australských travních porostech. Fraser et al., (2016) mapovali s pomocí dat z UAS subarktickou vegetaci tundry v Kanadě, kde dokázali klasifikovat krajinný pokryv do 11 tříd na úrovni druhů s průměrnou přesností klasifikace 82 %. Autoři konstatují, že výsledky jsou velmi dobré a doporučují mapování vegetace s pomocí UAS jako slibnou a efektivní metodu.

Mnoho studií také používá snímky z UAS nejen jako vstupní data do klasifikace vegetačního pokryvu, ale využívá jejich výhod jiným způsobem. Například Alvarez-Vanhard et al. (2020) ukazují, že pro zkoumání větších ploch je možné propojit informace ze satelitních a UAS snímků pro zlepšení výsledků klasifikací. UAS snímky mohou také poskytnout možnost vytyčení trénovacích ploch pro klasifikaci satelitních snímků. V neposlední řadě studie oceňuje flexibilitu práce s UAS při mapování vegetace. Yan et al. (2019) použili UAS k víceúhlovému snímání vegetace, kterou následně klasifikovali a Sankey et al. (2017) kombinovali multispektrální, hyperspektrální a lidarový senzor na UAS k optimalizování klasifikačních výsledků. Snímkování z UAS lze využít dokonce k mapování terénu pod hustou vegetací (Meng et al., 2017).

Dobrý příklad využití výhod UAS v zemědělství ukazuje Csillik et al. (2018), když s jeho pomocí klasifikovali teplomilné porosty v Kalifornii, kde identifikovali citrusovníky s přesností 96 %. Tato studie navíc poprvé využila při mapování citrusovníků klasifikaci na bázi neurálních sítí, která se velmi osvědčila. Lehmann et al. (2015) využili UAS v lesnictví, a to při identifikaci dubů, napadených polníkem dvojtečným. Na základě této studie mohou být tradiční lesnické metody na boj se škůdci výrazně zefektivněny a zavedená opatření mohou cílit přímo na všechny napadené stromy.

2.6 Mapování mokřadů s využitím DPZ

Mokřady jsou jedním z nejdůležitějších světových ekosystémů, a to zejména díky své schopnosti vázat vodu a bránit záplavám a pomoci při obnově zásob podzemní vody. Zároveň váží velké množství biomasy, takže jsou důležitým článkem přírodního cyklu uhlíku (Fraser & Keddy, 2005). Pro lepší porozumění jejich vodnímu režimu a pro jejich ochranu je nutné pečlivé dlouhodobé i sezónní sledování jejich dynamiky. Tradiční vědecké metody monitoringu mokřadů spočívaly především v terénních průzkumech. Metody DPZ dokážou tento proces zefektivnit a zrychlit. Mnohé studie z celého světa tento potenciál potvrzují, ale zároveň upozorňují, že klasifikace komplexní a dynamické vegetace mokřadů je velmi náročná a je vhodné používat data z více zdrojů (Bhatnagar et al., 2021; Kaplan & Avdan, 2018).

Ve studiích, zabývajících se monitoringem mokřadů s využitím DPZ, najdeme různé přístupy k této problematice. Kaplan & Avdan (2018) analyzovali změny vegetačního indexu NDVI a teploty povrchu v Balikdamských mokřadech ve středním Turecku v měsíčních intervalech ze satelitních snímků. S pomocí snímků z UAS dokázali v zájmovém území nalézt několik typů povrchu a analýzou snímků z družic Sentinel a Landsat k nim přiřadili typy vývoje vegetace a teploty povrchu během roku. Wang et al. (2014) použili data senzoru Thematic Mapper satelitů Landsat pro multitemporální analýzu typů krajinného pokryvu v mokřadních oblastech provincie Ťiang-su ve východní Číně. Ke klasifikaci byla použita metoda rozhodovacího stromu založená na odrazivosti v různých spektrálních pásmech a hodnotách indexu NDVI. Výsledky klasifikací dosahují přesnosti vyšší než 90 %, ale autoři upozorňují, že klasifikace zamokřených oblastí je náročná i jen při rozlišování základních typů krajinného pokryvu a doporučují hlubší výzkum a testování složitějších metod a pokročilých technologií.

V jiných studiích autoři zabíhají do podrobnějšího zkoumání mokřadních ekosystémů a klasifikují jejich druhové složení. K tomu se využívá různých metod, umožňujících využití vyššího prostorového rozlišení, než jaké poskytují satelitní snímky. Jedna z takových metod je letecké laserové skenování, které využívají Zlinszky et al. (2012), kteří s jeho pomocí klasifikovali vegetaci v mokřadech v okolí jezera Balaton. S použitím metody rozhodovacího stromu dosáhli autoři u nemokřadních porostů přesnosti přes 97 % a pro převládající druhy v mokřadním porostu přes 72 %. Přímou klasifikačním algoritmem bylo rovněž zahrnuto hodnocení stavu rákosových porostů, jehož přesnost byla většinou přes 80 %. Výsledky klasifikací považují autoři za uspokojivé, a i přes pravděpodobnou nižší přesnost oproti práci s hyperspektrálními daty, v kombinaci s multispektrálním snímkováním mohou být výsledky srovnatelné a mapování snadno opakovatelné.

Mnoho studií, zabývajících se posuzováním kvality mokřadů a analyzujících jejich druhové složení, využívá, podobně jako tato práce, technologií snímkování z UAS. Podle Du et al. (2021) platí, že „s rychlým vývojem technologie UAS se hyperspektrální data s vysokým prostorovým rozlišením z těchto přístrojů stala ideální pro přesnou klasifikaci mokřadních společenstev“. Jejich studie se zabývala srovnáváním objektových a pixelových klasifikačních metod při klasifikaci těchto snímků při použití různých metod strojového učení. Ukázali, že při určování druhového složení jsou efektivnější metody OBIA, kterými při kombinaci s metodou RF dosáhli celkové přesnosti 88 %. V závěru je upozorněno, že další výzkum se může zabývat konkrétními spektrálními příznaky, které lze neefektivněji využít pro rozlišení mokřadních společenstev. Jiná čínská studie (Fu et al., 2021) se zabývala srovnáváním přesnosti různých klasifikačních algoritmů při zkoumání vegetačního pokryvu významných krasových mokřadů v jihočínském krasu. Používali metody OBIA kombinované se strojovým učením a nejlepší výsledky klasifikace dosahovaly přesnosti přes 85 %. Studie rovněž i přes uspokojivé výsledky doporučuje zahrnout multitemporální snímkování a více spektrálních pásem.

Michez et al. (2016) použili snímky z UAS pro studium výskytu několika invazních druhů na území dvou mokřadů ve Valonii. Klasifikace byla provedena s využitím algoritmu RF a dosáhla uspokojivých výsledků (97 %) pouze pro jeden ze tří zkoumaných druhů. Zbylé dva druhy určila s přesností pouze kolem 70 % a podle závěru studie není možné z klasifikačního výsledku těchto druhů vycházet při rozhodování o praktických operacích pro ochranu mokřadu. Boon et al. (2016) zkoumali přírodní poměry jihoafrického mokřadu východně od Pretorie, výrazně přeměněného lidskou činností. Jejich výzkum nevyužívá klasifikaci vzniklého obrazu pro studium krajiny, ale zaměřuje se na vizualizaci dat tvorbou 2D i 3D modelů krajiny a spojuje zkoumání stavu vegetačního pokryvu, hydrologického režimu a geomorfologických poměrů oblasti. Výsledky studie jsou prezentovány jako vhodný podklad k dalšímu studiu oblasti a pro praktickou aplikaci při obnově důležitých funkcí mokřadu. Studie také vyzdvihuje nízkou cenu, flexibilitu a velmi dobré prostorové rozlišení, které technologie UAS při studiu mokřadů poskytují.

Bhatnagar et al. (2021) a Alvarez-Vanhard et al. (2020) také při studiu větších zamokřených oblastí navrhuje použít data z UAS pro tvorbu trénovacích ploch pro klasifikaci satelitních snímků. Obě studie pracovaly s multitemporálními daty pro co nejlepší přesnost a dosáhly uspokojivých výsledků použitím stejného algoritmu RF. Jak udává Bhatnagar et al. (2021), pro monitoring mokřadů je použití metod DPZ významným zlevněním a ulehčením, které umožňují zejména snímky z UAS, díky kterým dosahují výsledné klasifikace dostatečné přesnosti. Dobrých výsledků dosahují také Knoth et al. (2013), kteří využívají, stejně jako tato práce, UAS k mapování rašelinišť na úrovni druhů. Čtyři třídy nejčastěji se vyskytujících druhů v mokřadech severozápadního Německa dokázali klasifikovat s pomocí OBIA s přesností 91 %. Tato studie předpovídá UAS důležitou roli v budoucím rozvoji mapování mokřadní vegetace.

UAS bylo k monitoringu mokřadů využito také v Česku, například Lenzioch et al. (2021) s jeho pomocí monitorovali Rokytskou sláť a měřili na její ploše hodnotu vegetačních indexů, ale také výšku vodní hladiny a vlhkost půdy. Tyto veličiny byly klasifikovány s pomocí algoritmů strojového učení a výsledky studie vedly k lepšímu porozumění hydrologického cyklu mokřadu.

2.7 Použití technologie DPZ v Krkonoších

Tato práce je pokračováním dlouhodobého systematického využívání technologií DPZ při studiu vegetace v Krkonoších ve spolupráci se správou KRNP. Technologie DPZ se zde využívaly k mapování druhového složení nebo krajinného pokryvu již mnohokrát, a to s využitím leteckého nebo satelitního snímkování, ale také i UAS. Kupková et al. (2017) použili data ze satelitu Sentinel-2A a leteckých hyperspektrálních senzorů (AISA Dual a APEX) při klasifikaci druhového složení vegetace cenných partií krkonošské tundry. Nejlepších klasifikačních výsledků bylo dosaženo při pixelové klasifikaci metodou

SVM hyperspektrálních snímků a celková přesnost přesahovala 84 %. Výsledky prokázaly, že použití volně dostupných satelitních dat vede k výrazně nižší přesnosti a některé třídy travnatých ploch na nich nebyly rozlišitelné. Jejich výhodou je ale širší možnost multitemporálních analýz proti leteckým datům. Další studie (Potůčková et al., 2021) se zaměřila na archivní letecké snímky Krkonoš, na kterých studovala změny krajinného pokryvu. Podle výsledků studie se za posledních 80 let změnil typ krajinného pokryvu na 44% sledované plochy, a to zejména vlivem zarůstání otevřených travnatých ploch vyšší vegetací. Jiná studie (Jelének et al., 2014) zkoumala stav lučních porostů v Krkonoších s využitím laboratorních i obrazových spektroskopických metod.

Další významnou částí výzkumu Krkonoš tvoří studie, zaměřené na polskou část pohoří, kde se nachází Karkonoski Park Narodowy (KPN), navazující přes státní hranici na KRNAP. Marcinkowska et al. (2014) využili data hyperspektrálního leteckého senzoru APEX pro klasifikaci vegetačních společenstev na zájmovém území v západních Krkonoších. Na tvorbu map vegetačního pokryvu byla použita klasifikační metoda SVM a celková přesnost klasifikace dosáhla 79 %. Senzor APEX využili i Jarocińska et al. (2016) při zkoumání stavu lučních porostů na české straně Krkonoš. Autoři nejprve klasifikovali krajinný pokryv lokality, aby našli nezastavěné a nezalesněné plochy, na kterých následně zkoumali hodnoty vegetačních indexů. Další důležitý výzkum (Zagajewski et al., 2021) zkoumal druhové složení lesů na velké ploše uvnitř KPN. Satelitní snímky oblasti z Landsatu 8 a Sentinelu-2 byly klasifikovány s pomocí několika metod, z nichž nejlepší celkové přesnosti, 86,5 %, dosáhla metoda SVM.


Jediný výzkum na území KRNAPu, věnující se rašeliništím s využitím metod DPZ, je systematicky prováděn na Úpském rašeliništi ve východních Krkonoších s využitím multispektrálních i hyperspektrálních senzorů na UAS. Poslední výzkumná zpráva probíhajícího projektu (Kupková et al., 2020) popisuje výsledky klasifikací rašeliniště na úrovni druhů. Nejlepších výsledků dosáhla OBIA s využitím algoritmu SVM na multitemporálním hyperspektrálním kompozitu, jejíž celková přesnost dosáhla 86 %. Při výzkumu byly srovnávány přesnosti klasifikací multispektrálních a hyperspektrálních snímků a klasifikací snímků nasnímaných v různých termínech. Zároveň byly také analyzovány změny ploch, které jednotlivé druhy v jednotlivých měsících zabíraly.

Mimo články v recenzovaných časopisech se využitím DPZ v KRNAPu zabývalo také několik bakalářských a diplomových prací, které se často zabývaly klasifikačními metodami nebo mapováním krkonošské vegetace (Andrštová, 2014; Roubalová M, 2019; Soudková, 2014).

3 Zájmové území

3.1 Rašeliniště a mokřady v KRNAPu


Na území nejstaršího českého národního parku, vyhlášeného v nejvyšším českém pohoří, Krkonoších, se nachází několik pro střední Evropu unikátních typů ekosystémů. Mimo pralesovité horské smrčiny, květnaté louky a arкто-alpickou tundru mezi ně patří také rašeliniště. Celková plocha krkonošských rašelinišť je asi 268 ha na asi 60 různých lokalitách. Mezi nimi jsou nejznámější a nejvýznamnější Úpské rašeliniště v západních Krkonoších a Pančavské rašeliniště ve východní části pohoří. Tato dvě území patří dle Ramsarské konvence mezi nejvýznamnější mokřady světa (Ramsar Sites Information Service, 2005). Rašeliniště jsou specifickým typem mokřadů. Zatímco mokřady jsou definovány jako jakákoliv „území bažin, slatin, rašelinišť i území pokrytá vodou“ (Ramsar Convention Secretariat, 2013), rašeliniště musí splňovat další podmínky. Jejich hlavní charakteristikou je postupné ukládání odumřelých zbytků rostlin v zamokřených místech s nedostatkem kyslíku (NP Šumava, 2019). Krkonošská rašeliniště jsou svými poměry podobná rašeliništím v severní Evropě a vyskytuje se na nich velké množství glaciálních reliktních druhů (Správa KRNAP, 2022). Vyskytují se zde dva hlavní typy rašelinišť, kterými jsou otevřená horská vrchoviště, a lesní rašeliniště, na kterých je zamokřené území také zalesněné. Pro tuto práci byly vybrány tři méně významné lokality v západní části KRNAPu (viz obr. 1): Hraniční louka, patřící mezi vrchoviště a Alfrédka a Jakšín, které patří mezi lesní rašeliniště, na jejichž území byl les částečně vykácen.



Obrázek 1: Zájmové území na mapě KRNAPu (zdroj: ARCDATA PRAHA (2016), ČÚZK (2022))

3.2 Hraniční louka

Největší (13,5 ha) a nejvýznamnější ze všech zkoumaných ploch je Hraniční louka, nacházející se na východním svahu hory Luboch (1296 m n. m.) v nadmořské výšce přibližně 1250 m n. m. Jedná se o mimořádně cenné území se zachovalými typickými znaky horského rašeliniště – mozaikami horských a rašelinných smrčín (smrk ztepilý, *Picea abies*) a otevřeného rašeliniště (porost *Sphagnum* sp.) (viz obr. 3). Jde o významnou součást biotopu tetřívka obecného (*Lyrurus tetrix*) a typické rašelinné vegetace. Mezi další významné druhy, které budou na tomto území klasifikovány se zde vyskytuje borovice kleč (*Pinus mugo*), ostřice bažinná (*Carex limosa*), suchopýrek trsnatý (*Trichophorum cespitosum*), vlochyně bahenní (*Vaccinium uliginosum*). V menším množství lze nalézt také ostřici zobánkatou (*Carex rostrata*) nebo suchopýr pochvatý (*Eriophorum vaginatum*). Lokalita byla v minulosti částečně odvodněna, a i když je větší část území v dobrém stavu, bylo rozhodnuto o uskutečnění revitalizačních opatření (Volf et al., 2019). Klasifikována byla pouze jádrová část rašeliniště, kde nerostl vzrostlejší les, jejíž rozloha je 7,4 ha (viz obr. 2).



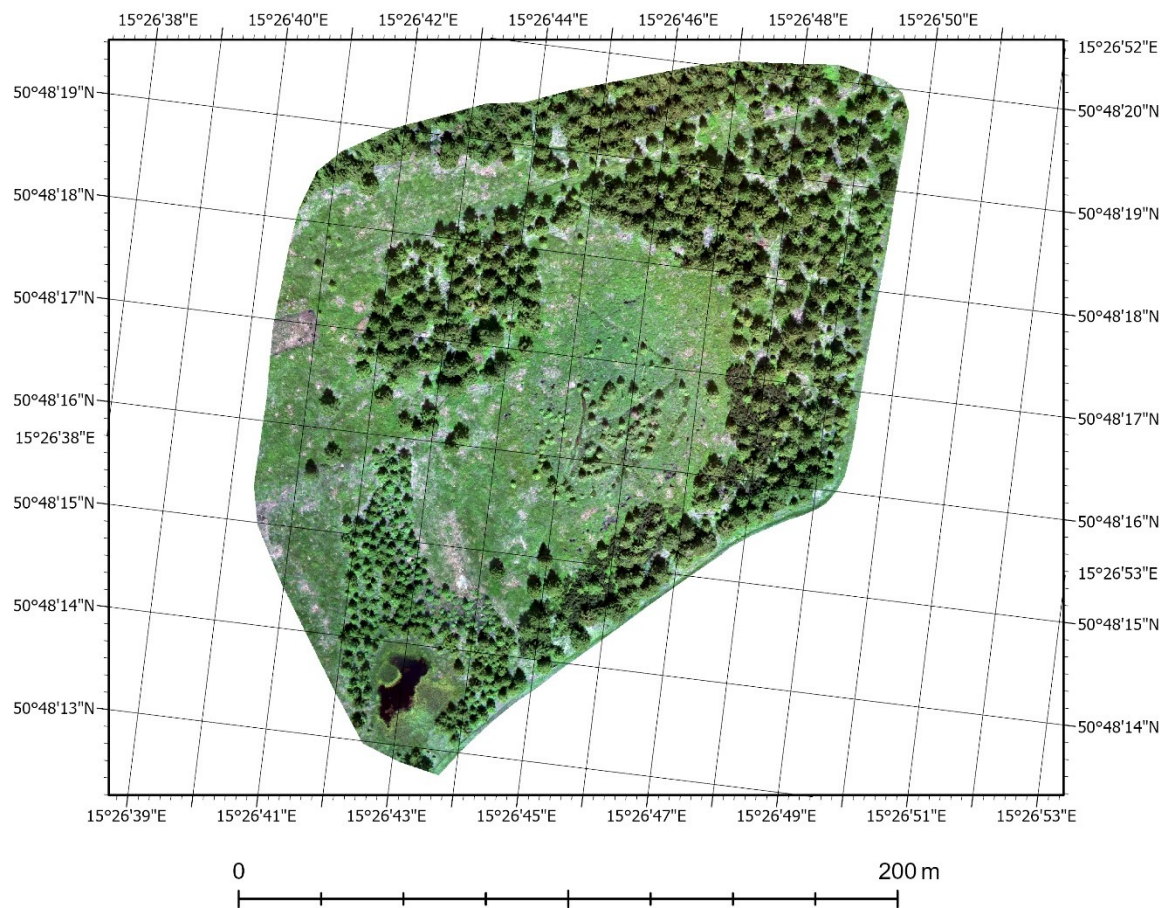
Obrázek 2: Hraniční louka, ortomosaika



Obrázek 3: Hraniční louka (Autor: Lucie Kupková)

3.3 Alfrédka

Tato menší cenná zamokřená lokalita se nachází na rozvodnici v sedle severovýchodně od Mrtvého vrchu (1059 m n. m.). Rozloha rašeliniště je 1,7 ha a nachází se v nadmořské výšce 1050 m n. m. Klasifikované území v sobě zahrnuje i jeho nejbližší okolí a jeho rozloha je 3 ha (viz obr. 4). V minulosti bylo rašeliniště odvodněno sítí kanálů a revitalizace byla částečně provedena v roce 2018. Jedná se také o stanoviště typických specializovaných druhů, včetně tetřívka obecného (*Lyrurus tetrix*). Kromě rašeliníku (*Sphagnum* sp.), smrku ztepilého (*Picea abies*) a lokálně nepůvodní borovice kleč (*Pinus mugo*) byly na této lokalitě identifikovány v významném množství také třtina chloupkatá (*Calamagrostis villosa*), brusnice borůvka (*Vaccinium myrtillus*), bezkolonec modrý (*Molinia caerulea*) a ostřice zobánkatá (*Carex rostrata*) (viz obr. 5) (Volf et al., 2019).



Obrázek 4: Alfrédka, ortomozaika



Obrázek 5: Alfrédka (Autor: Viera Horáková)



Obrázek 7: Jakšín (Autor: Viera Horáková)

4 Použitá data a metodika

4.1 Použitá data

4.1.1 Snímky UAS

Snímky třech rašelinišť byly pořízeny týmem Laboratorní a obrazové spektroskopie (TILSPEC, www.tilspec.cz) z Přírodovědecké fakulty UK 14. a 15. července 2021. V oba dny snímkování bylo počasí nepříznivé a práci komplikoval silný vítr. Nakonec se ale podařilo pořídit homogenní data bez oblačnosti (pro Hraniční louku a Alfrédku nalétnutá za slunečného počasí a pro Jakšín za podmínek stabilní oblačnosti (viz obr. 8). Pro snímkování byl použit bezpilotní dron DJI Phantom 4 Multispectral s prostorovým rozlišením 0,05 m. Přístroj využívá technologii Real Time Kinematics (RTK) pro přesnou lokalizaci snímků, obsahuje sluneční senzor a měří hodnoty DN v 5 pásmech: Modrém (450 nm \pm 16 nm), Zeleném (560 nm \pm 16 nm), Červeném (650 nm \pm 16 nm), Red Edge (RE, 730 nm \pm 16 nm) s Blízkým Infračerveném (NIR, 840 nm \pm 26 nm) (DJI, 2019). V terénu byly s centimetrovou přesností zaměřeny čtyři vlíčovací body pro každou ze sledovaných lokalit.



Obrázek 8: ukázka snímku z UAS, Hraniční louka

4.1.2 Terénní data

Trénovací a validační data vegetačních tříd krajinného pokryvu byla sesbírána v průběhu léta 2021 botaniky z KRNAPu. Pro borovici kleč (*Pinus mugo*), smrk ztepilý (*Picea abies*) a třídy neobsahující živou vegetaci (vodní plochy, zastíněné plochy, mrtvá vegetace a holá organozem) byly další vzorkovací plochy doplněny nad připravenou ortomozaikou zájmových území, složenou ze snímků UAS. Výsledné polygony byly rozpuřeny a 50 % ploch bylo použito na trénování klasifikačních algoritmů a 50 % ploch na validaci vzniklých map vegetačního pokryvu.

4.2 Klasifikované třídy vegetačního pokryvu

Na všech rašeliništích bylo klasifikováno dohromady 12 následujících tříd vegetace (přesný výskyt tříd v jednotlivých rašeliništích viz kapitola 4.3.2).

4.2.1 Smrk ztepilý (*Picea abies*)

Smrk (viz obr. 9) se nachází na všech sledovaných plochách a jde o nejdůležitější českou lesnickou dřevinu a nejběžnější součást střeoevropských lesů. Přirozeně roste v horských polohách a tvoří horní hranici lesa na středně až silně zamokřených spíše kyselejších půdách. Vlivem umělého pěstování se rozšířil i do nižších oblastí, kde monokultury trpí vývraty a napadáním škůdci. V krkonošských rašeliništích jde ovšem o přirozený výskyt (Skalická & Skalický, 1988).



Obrázek 9: smrk ztepilý (*Picea abies*) (Autor: Lucie Červená)

4.2.2 Rašelina (*Sphagnum* sp.)

Holý porost rašelínku není ve sledovaných územích příliš častý, ale byl klasifikován ve všech lokalitách a jeho podrost tvoří podstatnou část ekosystému rašelinišť. Tato skupina mechů je velmi dobře adaptována na kyselé horské prostředí chudé na živiny a prosperuje v zamokřených lokalitách po celém světě. Z globálního hlediska se jedná o jeden z nejvýznamnějších rostlinných rodů na Zemi, jelikož roste na přibližně 1,5 % její souše a je důležitou součástí uhlíkových cyklů. Rod *Sphagnum* (viz obr. 10) má mnoho druhů, které se od sebe liší vzhledem, ale někdy i funkcí v ekosystému a mohou být skvělými indikátory zdravého přírodního prostředí (Rydin & Jeglum, 2013).



Obrázek 10: rašelínku (*Sphagnum* sp.) (Zdroj: Wikimedia commons)

4.2.3 Borovice kleč (*Pinus mugo*)

Kleč (viz obr. 11) je keřovitá borovice, tvořící hlavní část porostu nad hranicí lesa v nejvyšších českých horách. Původní výskyt zahrnoval jen Krkonoše, Šumavu a Jizerské hory, ale v minulosti byl tento druh vysazen i do nižších poloh a na ostatní česká pohoří. Nad hranicí lesa plní vodoochrannou a půdoochrannou funkci (Skalická, 1988) a nachází se na Hraniční louce a na Alfrédce.



Obrázek 11: borovice kleč (*Pinus mugo*) (Zdroj: *Wikimedia commons*)

4.2.4 Vločyně bahenní (*Vaccinium uliginosum*)

Vločyně bahenní (viz obr. 12) patří mezi borůvkovité (*Vacciniaceae*) a tvoří nízký keříčkový porost na sušších okrajích vrchovišť, v rašelinných borech a mezi kosodřevinou. Roste i na rašeliništích nižších poloh, ale těžiště výskytu je v montánním až subalpínském stupni na kamenitých půdách (Čvančara, 1990). Ze zájmových území byla zjištěna na Hraniční louce a na Jakšíně.



Obrázek 12: vločyně bahenní (*Vaccinium uliginosum*) (Zdroj: *Wikimedia commons*)

4.2.5 Bezkolenec modrý (*Molinia caerulea*)

Jedná se o lipnicovitou (*Poaceae*) travinu (viz obr. 13), rostoucí převážně na vápnatých slatiništích, rašeliništích a střídavě vlhkých loukách. V Česku roste ve vyšších polohách na slunečných stanovištích otevřených luk a mokřadů (Pladias, 2022). Roste pouze na dvou ze sledovaných lokalit, a to na Alfrédce a Jakšíně.



Obrázek 13: bezkolenec modrý (*Molinia caerulea*) (Autor: Červená, 2022)

4.2.6 Brusnice borůvka (*Vaccinium myrtillus*)

Tento hojně se vyskytující druh keříčkovitého vzhledu (viz obr. 14), rostoucí zejména v acidofilních jehličnatých i listnatých lesích, na vřesovištích, pastvinách, suťových polích a okrajích rašelinišť, se na sledovaných plochách vyskytuje na Alfrédce a Jakšíně. Prosperuje na kyselých vlhkých půdách chudých na živiny a roste často pospolitě v rozlehlých porostech. Vyskytuje se na celém území Česka, ale v teplejších lokalitách vzácněji (Čvančara, 1990).



Obrázek 14: brusnice borůvka (*Vaccinium myrtillus*) (Zdroj: Wikimedia commons)

4.2.7 Třtina chloupkatá (*Calamagrostis villosa*)

Třtina chloupkatá (viz obr. 15) je důležitou součástí porostu krkonošských rašelin, roste v polostinných místech a méně vlhkých částech mokřadů. Vyhovují jí kyselé půdy chudší na živiny a těžiště jejího výskytu je na subalpínských loukách, mezi kosodřevinou a v acidofilních smrčinách (Pladius, 2022). Také roste pouze na Alfrédce a na Jakšíně.



Obrázek 15: třtina chloupkatá (*Calamagrostis villosa*) (Autor: Lucie Červená)

4.2.8 Ostřice bažinná (*Carex limosa*)

Tato rostlina (viz obr. 16) také patří mezi lipnicovité (Poaceae) a je silně vázána na chladnější trvale nebo periodicky zamokřené oblasti chudé na živiny. V Česku patří mezi silně ohrožené druhy a roste pouze na horských rašeliništích, kde vyžaduje velké množství slunečního svitu (Pladius, 2022). Ze sledovaných území byla nalezena pouze na Hraniční louce.



Obrázek 16: ostřice bažinná (*Carex limosa*) (Zdroj: Wikimedia commons)

4.2.9 Suchopýr pochvatý (*Eriophorum vaginatum*)

Tato lipnicovitá rostlina (viz obr. 17), klasifikovaná pouze na Jakšíně, je dalším indikátorem chladných kyselých zamokřených půd chudých na živiny. Vyskytuje se převážně na vrchovištích a rašeliništích, ale může růst i v acidofilních lesích (Pladias, 2022).



Obrázek 17: suchopýr pochvatý (*Eriophorum vaginatum*) (Zdroj: *Wikimedia commons*)

4.2.10 Ostřice zobánkatá (*Carex rostrata*)

Další z druhů ostřic (viz obr. 18) patří také mezi druhy hojné v mokřadech a rašeliništích, na chladnějším a kyselejších lokalitách. Klasifikována byla pouze na lokalitě Alfrédka. Roste nejen v horských rašeliništích, ale i v nížinných zamokřených loukách (Pladias, 2022).



Obrázek 18: ostřice zobánkatá (*Carex rostrata*) (Zdroj: *Wikimedia commons*)

4.2.11 Suchopýrek trsnatý (*Trichophorum cespitosum*)

Suchopýrek trsnatý (viz obr. 19) je v Česku zařazen mezi ohrožené druhy a je vázaný na velmi kyselé lokality velmi chudé na živiny. Roste jen na alpinských trávnicích a v otevřených mokřadech, jelikož je světlomilnou rostlinou a nesnáší stín (Pladias, 2022). Tvoří podstatnou část porostu otevřené části Hraniční louky, ale na zbylých dvou lokalitách se nevyskytuje.



Obrázek 19: suchopýrek trsnatý (*Trichophorum cespitosum*) (Zdroj: *Wikimedia commons*)

4.2.12 Třídy neobsahující vegetaci

Na území rašelinišť bylo pro lepší přesnost klasifikace třeba identifikovat několik tříd pro místa, kde chybí vegetace nebo ji klasifikační algoritmus nemá šanci rozpoznat. Specifické třídy byly utvořeny pro vodní plochy a zamokřenou organozem bez vegetace ve vyschlých rašelinných tůňkách (viz obr. 20). Další třída, která se vykytovala v datech snímaných za bezoblačného počasí, je stín (zejména od vyšších stromů). Poslední z těchto tříd, vysušená vegetace, zahrnuje stojící uschlé stromy a padlé kmeny nebo větve, seschlou a mrtvou vegetaci. Všechny tyto třídy byly klasifikovány na všech rašeliništích a poslední dvě z nich nebyly nasbírány v terénu, ale byly identifikovány při práci s hotovými ortomozaikami.




Obrázek 20: holá organozemě na Hraniční louce (Autor: *Viera Horáková*)

4.3 Předzpracování dat

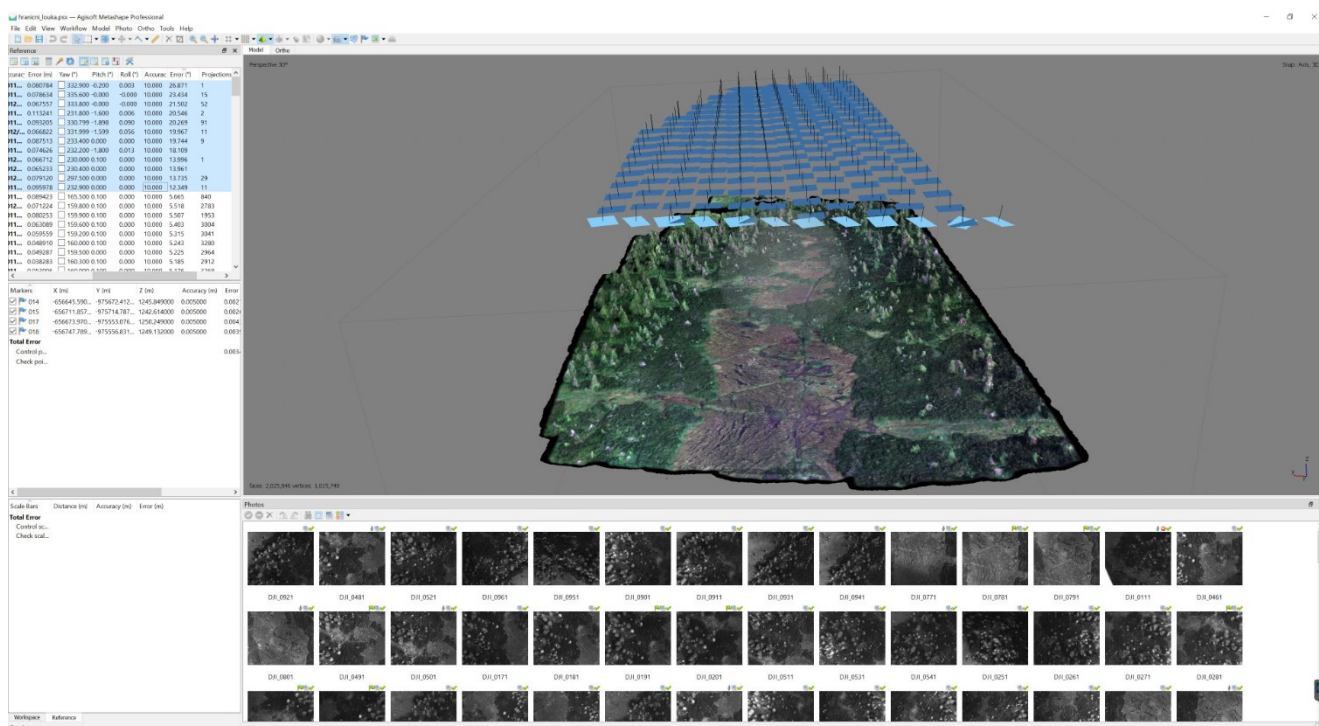
4.3.1 Tvorba ortomozaiek

Ortomozaiky ze snímků UAS byly vytvořeny v programu Agisoft Metashape Professional. Nejprve byly do softwaru nahrány multispektrální snímky, automaticky byla z metadat určena jejich poloha a orientace a bylo spočteno řídké bodové mračno. Přesnost orientace a polohy snímků byla optimalizována s pomocí RTK, ale stále nebyla uspokojivá, a proto byly v dalším kroku parametry zpřesněny s pomocí vřícovacích bodů. V dalším kroku bylo utvořeno husté bodové mračno, digitální model reliéfu a vygenerována ortomozaika, převedená do souřadnicového systému S-JTSK. Ta byla z programu exportována a uložena. Stejně bylo postupováno při tvorbě všech tří ortomozaik.

Během práce s hotovými ortomozaikami bylo zjištěno, že na některých místech poblíž okrajů se vyskytovaly zvláštní rozmazané artefakty a posuny (viz obr. 21). Nejvýrazněji se tyto vady projeví na Hraniční louce, ale dobře rozpoznatelné byly i na zbylých dvou rašeliništích. Forma poškození ortomozaiek vzbuzovala podezření na chybu v zarovnání nebo orientaci snímků a bylo nutné vrátit se v procesu skládání snímků zpět na začátek. Po kontrole kvality snímků a dalších parametrů a konzultaci s vývojáři softwaru Agisoft bylo zjištěno, že chyba byla způsobena příliš velkým sklonem dronu při otáčení na okraji zájmového území, což bylo pravděpodobně důsledkem větrných podmínek během snímání. Chyba neovlivňovala kvalitu snímků, ale byla rozpoznatelná při investigaci chyb v orientaci snímku vůči kolmému směru k povrchu (viz obr. 22). Několik vadných snímků pro každou plochu bylo v Agisoftu identifikováno a po jejich odstranění artefakty již nebyly přítomné. Nicméně kvůli tomu také z analýzy byly vyjmuty některé menší části zájmového území na jeho okrajích.



Obrázek 21: ukázka artefaktů v severních částech ortomozaiky Hraniční louky



Obrázek 22: vadné snímky v severní části Hraniční louky

Výsledné ortomozaiky byly oříznuté o okrajové plochy cest a zubaté nebo fragmentované okraje, čímž byla zájmová území vymezena. Základní radiometrické korekce byla provedena automaticky za pomoci slunečního senzoru umístěného na muntispektrální kameře UAS.

4.3.2 Úpravy a hodnocení vstupních dat pro trénování (validaci)

Jak již bylo zmíněno výše, po důkladném prohlédnutí ortomozaiky byly pro zlepšení přesnosti klasifikace přidány některé nevegetační třídy a byla pro ně vybrána trénovací data. Jedná se o místa ve stínu vysoké vegetace a vysušenou nebo mrtvou vegetaci. Následně byla, s cílem optimalizovat trénovací fázi klasifikací, provedena analýza separability v softwaru ENVI 5.5, která spočítala Jeffriesovu-Matusitovu vzdálenost a index separability pro každou dvojici tříd a ukázala, které z tříd jsou špatně oddělitelné. Druhým ukazatelem separability tříd byly pixely trénovacích ploch zobrazené v rozptylogramu (scatterplotu), kde bylo možné nalézt konkrétní trénovací plochy, jejichž spektrální příznaky si byly navzájem podobné nebo blízké. U tříd, kde bylo možné bezpečně odebrat trénovací plochy nebo přidat nové (smrk ztepilý, borovice kleč, voda, zastíněné plochy, mrtvá vysušená vegetace), bylo následně manipulováno s trénovacími plochami tak, aby lépe reprezentovaly příslušnou třídu vegetačního pokryvu. Bylo odhaleno a odstraněno několik ploch, nasbíraných v terénu, které nekorespondovaly s ortomozaikou, resp. výskytem dané třídy na daném místě v terénu, a pro třídy smrku ztepilého (*Picea abies*) a borovice kleče (*Pinus mugo*) bylo z důvodu nízké separability

několik trénovacích ploch přidáno. Tento proces zlepšil přesnost klasifikace metodou MLC v průměru o 4,5 %. Charakteristiky výsledných vstupních dat pro trénování (validaci) jednotlivých rašelinišť shrnují tabulky 1-3.

Tabulka 1: Vstupní data pro trénování (validaci) pro lokalitu Hraniční louka

Hraniční louka			
Celková plocha	44,0 m ²		
třída	počet ploch	počet pixelů v plochách	rozloha ploch (m ²)
Holá organozem	1	187	0,47
Carex limosa	3	551	1,38
Pinus mugo	12	1795	4,49
Sphagnum sp.	4	1101	2,75
Picea abies	5	4001	10,00
Zastíněné plochy	5	1743	4,36
Vysušená vegetace	4	1342	3,36
Trichophorum cespitosum	10	6148	15,37
Vaccinium uliginosum	1	174	0,44
Vodní plochy	5	555	1,39

Tabulka 2: Vstupní data pro trénování (validaci) pro lokalitu Alfrédka

Alfrédka			
Celková plocha	19,1 m ²		
třída	počet ploch	počet pixelů v plochách	rozloha ploch (m ²)
Vaccinium myrtillus	5	911	2,28
Calamagrostis villosa	2	269	0,67
Pinus mugo	5	216	0,54
Molinia caerulea	2	203	0,51
Sphagnum sp.	1	16	0,04
Carex rostrata	1	191	0,48
Picea abies	7	2799	7,00
Zastíněné plochy	7	1236	3,09
Vysušená vegetace	9	1100	2,75
Vodní plochy	3	686	1,72

Tabulka 3: Vstupní data pro trénování (validaci) pro lokalitu Jakšín

Jakšín			
Celková plocha	18,7 m ²		
třída	počet ploch	počet pixelů v plochách	rozloha ploch (m ²)
Vaccinium myrtillus	6	1092	2,73
Calamagrostis villosa	1	34	0,09
Eriophorum vaginatum	1	34	0,09
Molinia caerulea	2	650	1,63
Sphagnum sp.	1	656	1,64
Picea abies	6	3640	9,10
Zastíněné plochy	2	204	0,51
Vysušené vegetace	3	758	1,90
Vaccinium uliginosum	1	189	0,47
Vodní plochy	2	221	0,55

4.4 Analýza dat

Analytická část práce spočívala v tvorbě map vegetačního pokryvu všech tří sledovaných území s pomocí několika klasifikačních metod. Práce s rastry byla prováděna primárně v softwaru ENVI 5.5, který umožňuje snadnou implementaci klasifikačních metod na vstupní ortomozaiky.

4.4.1 Metoda maximální věrohodnosti

Pro všechny tři plochy byl nejprve použit klasifikační algoritmus MLC ve výchozím nastavení v softwaru ENVI. Tato klasifikace byla provedena pro každou plochu několikrát během manipulace s trénovacími plochami a výsledek uvedený níže odpovídá nejpřesnějšímu výsledku v posledním stádiu trénovacích ploch.

4.4.2 Metoda Random forest

Na rozdíl od ostatních metod nelze algoritmus RF provést v ENVI 5.5, a proto byl k jeho výpočtu použit statistický software R. S pomocí přídatných balíčků a předem připraveného převzatého skriptu (vytvořeného pro účely klasifikace v projektech týmu TILSPEC www.tilspec.cz) byla metoda RF použita na všechna tři území se stejnými parametry. Algoritmus RF využívá dva parametry: ntree je počet rozhodovacích stromů, které výpočet použije a mtry je počet proměnných, mezi kterými algoritmus na každé křížovatce stromu rozhoduje. Při výpočtu bylo použito 1000 stromů (ntree) a parametr mtry byl ponechán na výchozí hodnotě, kterou je odmocnina z počtu klasifikovaných tříd (Belgiu & Drăgu, 2016).

4.4.3 Metoda Support vector machine

Tato klasifikace byla provedena v ENVI s výchozím nastavením, tedy s typem „kernel“ radial basis function a s parametrem gamma 0,2.

4.4.4 Metoda objektivě orientované klasifikace

OBIA byla taktéž provedena v softwaru ENVI s pomocí nástroje „Example based feature extraction“. V rámci segmentační fáze (Segment settings) v ENVI 5.5 byl zvolen segmentační algoritmus „Edge“, který je lepší na segmentaci v prostředí ostřejších hran mezi třídami a vhodnější na klasifikaci vegetace, než druhý algoritmus „Intensity“. V parametrech slučování (Merge settings) byl zvolen algoritmus „Full Lambda Schedule“, který spojí dohromady blízké segmenty s podobnými spektrálními příznaky. Dalším parametrem je „Scale level“, který určuje podrobnost segmentace (velikost segmentů) v první fázi a jeho vyšší hodnota vede k tvorbě méně segmentů. Parametr „Merge level“ určuje míru spojení příliš segmentovaných území. Tyto parametry byly nastaveny u každého sledovaného území třemi různými způsoby a byl zkoumán jejich efekt na výslednou přesnost klasifikace. V prvním pokusu byl zvolen „Scale level“ 20 a „Merge level“ 30, ve druhém při stejném pořadí 20 a 60 a při třetím pokusu 50 a 90. Tato nastavení byla použita na základě doporučení v Kupková et al. (2020), kde se ukázala jako nejlepší při klasifikaci Úpského rašeliniště. Velikost segmentačního „kernelu“, která se u více heterogenních oblastí doporučuje menší, byla vždy nastavena na 5 pixelů. Po provedené segmentaci byl zvolen klasifikační algoritmus SVM (opět na základě doporučení Kupková et al. (2020)), který přiřadil jednotlivé segmenty do tříd s využitím všech pásem (atributů) (Harris geospatial, 2022).

4.5 Hodnocení přesnosti klasifikací

Na výsledky klasifikace bylo aplikováno několik metod, hodnotících přesnost výsledných map. Nejprve byla v softwaru ENVI na základě validačních ploch sestavena chybová matice, ze které byla spočítána celková přesnost klasifikace a uživatelské a zpracovatelské přesnosti pro jednotlivé třídy (Jensen, 2005). Ve stejném softwaru byl spočten také Kappa koeficient pro každou klasifikaci. Následně byly nejlepší výsledky klasifikací srovnávány překrytím přes sebe a bylo analyzováno, v jak velké ploše se navzájem shodují a jak konzistentně přiřazují pixely do jednotlivých tříd. Shody klasifikací pro jednotlivé třídy byly vyjádřeny souhrnnou hodnotou shody klasifikací MA_T (shoda pro třídu T), převzatou od Kupková et al. (2022a), která je definována vzorcem $MA_T = M_{12} / (A_1 + A_2 - M_{12})$, kde M_{12} je plocha, ve které se shodují obě klasifikační metody v klasifikaci dané třídy a A_1 a A_2 jsou celkové plochy, na kterých byla třída klasifikována jednotlivými metodami. Shoda klasifikací MA_T , vyjádřená v procentech, je souhrnným číslem, vyjadřujícím shodu klasifikačních metod v klasifikaci dané třídy. Pro každou třídu a každou dvojici klasifikací bylo také spočítáno, jak velký podíl plochy klasifikovaný první klasifikační metodou se shoduje s klasifikací druhou metodou. Tímto postupem lze porovnat jednotlivé klasifikační metody a určit, které z nich ve kterých třídách pravděpodobně chybují méně.

5 Výsledky

Výsledky hodnocení přesnosti jednotlivých klasifikačních metod jsou shrnuty v této kapitole v tabulkách 5-15. Všechny výsledky pro jednotlivé lokality jsou shrnuty v příloze 1. Dvě nejpřesnější výsledné mapy vegetačního pokryvu pro každou lokalitu (vždy výsledky metod RF a OBIA) jsou přiloženy v přílohách 2-7. Výsledky analýzy překryvů jsou shrnuty v podkapitole 5.5 v tabulce 16 a grafech 1-3. Podrobnější výsledky analýzy překryvů, včetně map vzájemné shody tříd v tematických výstupech jednotlivých klasifikačních metod, se nachází v přílohách 8-14.

5.1 Maximální věrohodnost

Nejjednodušší algoritmus – metoda MLC dosáhla také nejméně přesných výsledků. Nejlepší průměrné přesnosti pro Hraniční louku, Alfrédku a Jakšín jsou v tomto pořadí 81,06 %, 81,54 % a 74,99 %. Na klasifikovaném území jsou běžné pixely, klasifikované jako jiná třída než celé jejich okolí. Tento efekt, známý jako „efekt soli a pepře“ (Duro et al., 2012) je běžný u pixelových klasifikací. Výsledky hodnocení přesnosti klasifikace jsou shrnuté v tabulkách 4-6.

Tabulka 4: Hodnocení přesnosti a rozlohy vegetačních tříd na Hraniční louce při klasifikaci metodou

MLC

Hraniční louka			
celková přesnost 81,06 %, Kappa koeficient: 0,77			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Holá organozem	95,19 %	99,44 %	0,1 %
Carex limosa	84,84 %	38,15 %	9,9 %
Pinus mugo	90,98 %	63,09 %	45,0 %
Sphagnum sp.	84,94 %	57,57 %	6,0 %
Picea abies	60,99 %	84,96 %	17,3 %
Zastíněné plochy	96,78 %	96,28 %	7,4 %
Vysušená vegetace	71,85 %	99,15 %	0,5 %
Trichophorum cespitosum	85,37 %	96,03 %	10,8 %
Vaccinium uliginosum	98,45 %	61,49 %	2,8 %
Vodní plochy	98,55 %	94,11 %	0,2 %

Tabulka 5: Hodnocení přesnosti a rozlohy vegetačních tříd na Alfrédce při klasifikaci metodou MLC

Alfrédka			
celková přesnost 81,54 %, Kappa koeficient: 0,78			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Vaccinium myrtillus	84,85 %	89,37 %	18,0 %
Calamagrostis villosa	45,42 %	17,58 %	9,3 %
Pinus mugo	92,24 %	40,56 %	6,1 %
Molinia caerulea	82,91 %	45,96 %	5,8 %
Sphagnum sp.	35,00 %	9,21 %	1,3 %
Carex rostrata	92,13 %	84,54 %	2,9 %
Picea abies	63,07 %	92,43 %	34,9 %
Zastíněné plochy	98,76 %	99,75 %	10,5 %
Vysušená vegetace	99,82 %	98,44 %	10,9 %
Vodní plochy	100,00 %	97,96 %	0,4 %

Tabulka 6: Hodnocení přesnosti a rozlohy vegetačních tříd na Jakšíně při klasifikaci metodou MLC

Jakšín			
celková přesnost 74,99 %, Kappa koeficient 0,68			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Vaccinium myrtillus	88,77 %	43,50 %	34,2 %
Calamagrostis villosa	67,50 %	27,27 %	2,6 %
Eriophorum vaginatum	59,46 %	47,83 %	1,1 %
Molinia caerulea	83,57 %	71,87 %	15,4 %
Sphagnum sp.	84,09 %	90,35 %	6,5 %
Picea abies	58,95 %	91,87 %	30,7 %
Zastíněné plochy	99,50 %	97,55 %	1,6 %
Vysušená vegetace	99,88 %	98,40 %	6,5 %
Vaccinium uliginosum	88,07 %	78,68 %	1,2 %
Vodní plochy	100,00 %	100,00 %	0,0 %

5.2 Random forest

Metoda RF dosáhla významně přesnějších výsledků než metoda MLC. Hraniční louka byla klasifikována s průměrnou přesností 89,95 %, Alfrédka s průměrnou přesností 91,57 % a přesnost klasifikace Jakšina byla opět o něco nižší – 82,65 %. Na výsledcích klasifikace RF je také rozpoznatelný „efekt soli a pepře“,

ale výrazně méně než u metody MLC. Ve výsledcích stojí za povšimnutí nulová přesnost klasifikace rašeliníku, kterou nejspíš způsobila velmi malá trénovací plocha. Výsledky hodnocení přesnosti klasifikace jsou shrnuté v tabulkách 7-9. Výsledné mapy krajinného pokryvu vzniklé klasifikací RF lze nalézt v přílohách 3, 5 a 7.

Tabulka 7: Hodnocení přesnosti a rozlohy vegetačních tříd na Hraniční louce při klasifikaci metodou

RF

Hraniční louka			
celková přesnost 89,95 %, Kappa koeficient 0,87			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Holá organozem	85,03 %	100,00 %	0,2 %
Carex limosa	85,02 %	77,98 %	2,9 %
Pinus mugo	95,46 %	80,94 %	47,2 %
Sphagnum sp.	78,90 %	88,68 %	1,3 %
Picea abies	79,59 %	88,01 %	22,9 %
Zastíněné plochy	97,99 %	98,55 %	8,0 %
Vysušená vegetace	85,23 %	99,55 %	0,8 %
Trichophorum cespitosum	96,84 %	90,42 %	15,8 %
Vaccinium uliginosum	66,84 %	90,21 %	0,6 %
Vodní plochy	96,01 %	99,44 %	0,4 %

Tabulka 8: Hodnocení přesnosti a rozlohy vegetačních tříd na Alfrédce při klasifikaci metodou RF

Alfrédka			
celková přesnost 91,57 %, Kappa koeficient 0,89			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Vaccinium myrtillus	92,16 %	90,22 %	17,0 %
Calamagrostis villosa	14,12 %	59,68 %	1,4 %
Pinus mugo	63,93 %	85,37 %	3,4 %
Molinia caerulea	54,27 %	93,91 %	1,2 %
Sphagnum sp.	0,00 %	0,00 %	0,8 %
Carex rostrata	85,39 %	74,51 %	4,8 %
Picea abies	96,71 %	86,82 %	52,0 %
Zastíněné plochy	97,19 %	100,00 %	12,2 %
Vysušená vegetace	99,21 %	100,00 %	6,6 %
Vodní plochy	100,00 %	95,50 %	0,6 %

Tabulka 9: Hodnocení přesnosti a rozlohy vegetačních tříd na Jakšíně při klasifikaci metodou RF

Jakšín			
celková přesnost 82,65 %, Kappa koeficient 0,76			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Vaccinium myrtillus	76,09 %	60,34 %	18,3 %
Calamagrostis villosa	80,00 %	60,38 %	0,9 %
Eriophorum vaginatum	45,95 %	58,62 %	0,8 %
Molinia caerulea	71,76 %	71,45 %	11,5 %
Sphagnum sp.	57,58 %	78,67 %	9,8 %
Picea abies	86,34 %	88,75 %	49,6 %
Zastíněné plochy	95,00 %	100,00 %	1,0 %
Vysušené vegetace	100,00 %	99,50 %	5,5 %
Vaccinium uliginosum	80,11 %	83,93 %	2,0 %
Vodní plochy	100,00 %	100,00 %	0,6 %

5.3 Support vector machine

Výsledky metody SVM byly méně přesné než výsledky metody RF, ale stále výrazně přesnější než výsledky metody MLC. Přesnost klasifikace Hraniční louky byla vyhodnocena na 85,27 %, Alfrédky na 90,54 % a přesnost klasifikace Jakšina byla 80,77 %. Z neznámých důvodů nebyla schopna tato metoda natrénovat na Alfrédce třídu rašeliníku a její výsledky vykazují znaky „efektu soli a pepře“, které jsou ale nejméně znatelné ze všech tří pixelových klasifikací. Výsledky hodnocení přesnosti klasifikace jsou shrnuté v tabulkách 10-12.

Tabulka 10: Hodnocení přesnosti a rozlohy vegetačních tříd na Hraniční louce při klasifikaci metodou SVM

Hraniční louka			
celková přesnost 85,27 %, Kappa koeficient 0,82			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Holá organozem	81,28 %	96,82 %	0,2 %
Carex limosa	65,70 %	52,22 %	9,7 %
Pinus mugo	86,17 %	70,95 %	41,3 %
Sphagnum sp.	71,54 %	82,28 %	1,6 %
Picea abies	70,53 %	83,51 %	18,9 %
Zastíněné plochy	98,04 %	94,77 %	9,7 %
Vysušená vegetace	87,54 %	99,48 %	0,8 %

třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Trichophorum cespitosum	94,36 %	89,04 %	15,6 %
Vaccinium uliginosum	87,05 %	78,87 %	1,4 %
Vodní plochy	95,10 %	97,04 %	0,6 %

Tabulka 11: Hodnocení přesnosti a rozlohy vegetačních tříd na Alfrédce při klasifikaci metodou SVM

Alfrédka			
celková přesnost 90,54 %, Kappa koeficient 0,88			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Vaccinium myrtillus	92,37 %	89,03 %	20,2 %
Calamagrostis villosa	14,89 %	60,94 %	1,6 %
Pinus mugo	52,97 %	67,84 %	2,1 %
Molinia caerulea	68,84 %	87,26 %	2,5 %
Sphagnum sp.	0,00 %	0,00 %	0,0 %
Carex rostrata	89,33 %	89,33 %	2,9 %
Picea abies	93,10 %	85,32 %	48,1 %
Zastíněné plochy	97,28 %	98,99 %	13,5 %
Vysušená vegetace	99,74 %	99,48 %	8,5 %
Vodní plochy	100,00 %	95,63 %	0,6 %

Tabulka 12: Hodnocení přesnosti a rozlohy vegetačních tříd na Jakšíně při klasifikaci metodou SVM

Jakšín			
celková přesnost 80,77 %, Kappa koeficient 0,73			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Vaccinium myrtillus	62,41 %	63,68 %	16,3 %
Calamagrostis villosa	45,00 %	62,07 %	0,3 %
Eriophorum vaginatum	32,43 %	52,17 %	0,8 %
Molinia caerulea	61,38 %	77,31 %	8,1 %
Sphagnum sp.	82,03 %	81,67 %	9,4 %
Picea abies	85,31 %	80,88 %	55,8 %
Zastíněné plochy	100,00 %	98,52 %	1,9 %
Vysušené vegetace	100,00 %	98,77 %	5,5 %
Vaccinium uliginosum	57,39 %	68,24 %	1,2 %
Vodní plochy	100,00 %	100,00 %	0,8 %

5.4 Objektově orientovaná klasifikace

I při nastavení různých segmentačních parametrů tato metoda vždy byla schopna poskytnout nejpřesnější výsledky klasifikace. U Hraniční louky bylo nejpřesnější nastavení „scale level“ 50 a „merge level“ 90, při kterém dosáhla metoda OBIA průměrné přesnosti 96,51 %. Při klasifikaci Alfrédky byl nejlepším nastavením pro přesnost klasifikace „scale level“ 20 a „merge level“ 60 a průměrná přesnost při tomto nastavení dosáhla 96,39 %. U poslední lokality, Jakšína, bylo nejlepších výsledků dosaženo opět při nastavení „scale level“ 50 a „merge level“ 90 a průměrná přesnost klasifikace byla 95,76 %. Nejlepší výsledky hodnocení přesnosti klasifikace jsou shrnuté v tabulkách 13-15. Výsledné mapy krajinného pokryvu vzniklé klasifikací RF lze nalézt v přílohách 2, 4 a 6.

Tabulka 13: Hodnocení přesnosti a rozlohy vegetačních tříd na Hraniční louce při klasifikaci metodou OBIA (scale level 50, merge level 90)

Hraniční louka			
celková přesnost 96,51 %, Kappa koeficient 0,96			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Holá organozem	100,00 %	66,08 %	1,4 %
Carex limosa	99,46 %	78,71 %	6,9 %
Pinus mugo	98,38 %	95,49 %	46,7 %
Sphagnum sp.	97,11 %	98,58 %	1,9 %
Picea abies	89,65 %	99,70 %	15,2 %
Zastíněné plochy	100,00 %	99,49 %	9,3 %
Vysušená vegetace	94,69 %	99,60 %	0,7 %
Trichophorum cespitosum	99,04 %	96,42 %	14,7 %
Vaccinium uliginosum	100,00 %	99,48 %	0,7 %
Vodní plochy	100,00 %	96,33 %	2,6 %

Tabulka 14: Hodnocení přesnosti a rozlohy vegetačních tříd na Alfrédce při klasifikaci metodou OBIA
(scale level 20, merge level 60)

Alfrédka			
celková přesnost 96,39 %, Kappa koeficient 0,95			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Vaccinium myrtillus	99,46 %	99,89 %	18,1 %
Calamagrostis villosa	69,47 %	79,82 %	4,9 %
Pinus mugo	99,54 %	88,98 %	10,2 %
Molinia caerulea	72,86 %	100,00 %	1,4 %
Sphagnum sp.	55,00 %	15,07 %	10,5 %
Carex rostrata	87,08 %	98,73 %	1,9 %
Picea abies	96,46 %	95,12 %	35,0 %
Zastíněné plochy	100,00 %	100,00 %	8,9 %
Vysušená vegetace	99,82 %	100,00 %	7,9 %
Vodní plochy	99,45 %	100,00 %	1,2 %

Tabulka 15: Hodnocení přesnosti a rozlohy vegetačních tříd na Jakšíně při klasifikaci metodou OBIA

Jakšín			
celková přesnost 95,76 %, Kappa koeficient 0,94			
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Vaccinium myrtillus	99,64 %	84,55 %	42,3 %
Calamagrostis villosa	100,00 %	61,54 %	17,0 %
Eriophorum vaginatum	100,00 %	100,00 %	0,5 %
Molinia caerulea	86,74 %	100,00 %	4,9 %
Sphagnum sp.	92,78 %	87,62 %	11,3 %
Picea abies	95,19 %	99,89 %	20,1 %
Zastíněné plochy	100,00 %	100,00 %	0,6 %
Vysušené vegetace	99,75 %	100,00 %	2,2 %
Vaccinium uliginosum	100,00 %	100,00 %	0,3 %
Vodní plochy	100,00 %	97,24 %	0,8 %

5.5 Analýza překryvů

Z analýzy překryvů byly získány počty shodně klasifikovaných pixelů pro dvojice klasifikací RF a SVM a RF a OBIA na každém území. Pro každou dvojici klasifikačních metod je výsledkem procento území, na


kterém se klasifikační metody shodovaly, a pro každou třídu shoda jedné klasifikační metody s druhou podle vzorce, popsaného v kapitole 4.5. Pro každou třídu a každou dvojici klasifikací byl také spočítán podíl shodně klasifikovaných pixelů vůči celkové rozloze třídy, a to z pohledu obou klasifikačních metod. Podrobné výsledky lze nalézt v příloze 8, zde jsou nejdůležitější výsledky shrnuty do tabulky 16 a grafů 1-3.

Tabulka 16: Shrnující tabulka shod překryvů mapových výstupů jednotlivých klasifikačních metod

	shoda RF a SVM	shoda RF a OBIA
Hraniční louka	75,56 %	66,12 %
Alfrédka	72,78 %	60,56 %
Jakšín	56,76 %	37,77 %

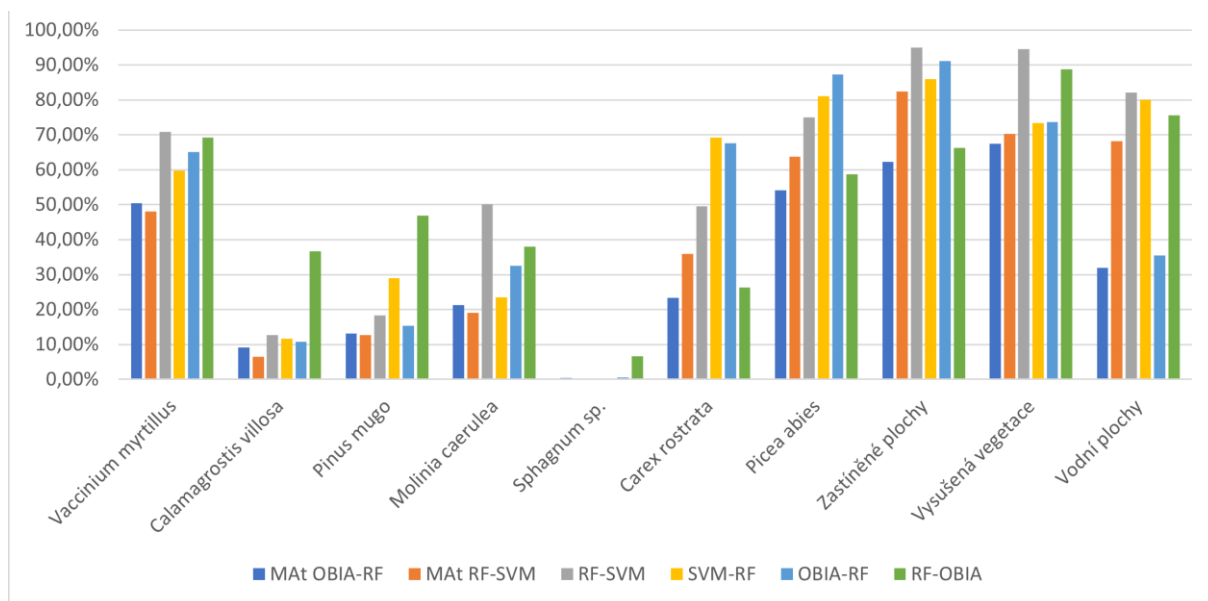
graf 1: Shody jednotlivých klasifikačních metod pro jednotlivé třídy na Hraniční louce

(MA_t jsou celkové shody, další shody jsou vždy vztaženy k rozloze třídy v první jmenované klasifikaci)




graf 2: Shody jednotlivých klasifikačních metod pro jednotlivé třídy na Alfrédce

(MA_t jsou celkové shody, další shody jsou vždy vztaženy k rozloze třídy v první jmenované klasifikaci)



graf 3: Shody jednotlivých klasifikačních metod pro jednotlivé třídy na Jakšíně

(MA_t jsou celkové shody, další shody jsou vždy vztaženy k rozloze třídy v první jmenované klasifikaci)




6 Diskuse


Jak bylo dle literatury možné očekávat (Kupková et al., 2017; Lu & Weng, 2007), nejnižší přesnost klasifikace vykazovala metoda MLC, ale zejména některé konkrétní třídy (například vodní plochy, vysušená vegetace, holá organozemě nebo *Trichophorum cespitosum*) byly podle srovnání s validačními plochami i touto metodou klasifikovány s uspokojivou přesností. O něco lepších výsledků bylo dosaženo s pomocí pixelových metod strojového učení SVM a RF a OBIA dosáhla nejlepší přesnosti (pro Hraniční louku 96,51 %, pro Alfrédku 96,39 % a pro Jakšína 95,76 %). Dle předpokladu byly s vysokou přesností klasifikovány nevegetační třídy, které jsou z RGB ortomozaiky rozeznatelné vizuálně. V případě jednotlivých druhů vegetace byly spektrální charakteristiky významně bližší, což vedlo k horší přesnosti. Více překvapivé byly rozdíly mezi jednotlivými plochami, kde se vyskytly velké rozdíly jak v celkové přesnosti, tak přesnosti klasifikace jednotlivých tříd. Zatímco na Hraniční louce a Alfrédce dosahovaly stejné klasifikační metody podobných přesností, mapy vegetačního pokryvu Jakšína, vzniklé za použití stejných metod, dosahovaly přesností o poznání menších. Výjimkou byla OBIA, která vykazovala podobně vysokou přesnost při klasifikaci všech území. Stejně tak se velmi lišily přesnosti, kterých dosáhly stejné klasifikační metody na různých lokalitách u stejných tříd – viz tabulky 17-19 v příloze 1. Na Hraniční louce stojí za povšimnutí přesnost klasifikace třídy holé organozemě, která byla nejvyšší při klasifikaci metodou MLC, a naopak nejnižší po použití metody OBIA. Na Alfrédce byla velmi špatně klasifikována třída rašeliníku (*Sphagnum* sp.) a třída třtiny chloupkaté (*Calamagrostis villosa*) byla u všech pixelových klasifikací klasifikována s přesností pod 40 %, zatímco OBIA u ní dosáhla přesnosti 75 %. OBIA dosáhla jako jediná uspokojivého výsledku také u suchopýrku pochvatého (*Eriophorum vaginatum*) na Jakšíně. Velký rozdíl mezi lokalitami Alfrédka a Jakšín byl v přesnosti klasifikace brusnice borůvky (*Vaccinium myrtillus*), která byla všemi klasifikačními metodami na Alfrédce klasifikována výrazně přesněji.

Dalším významnou odlišností byly rozdíly v rozlohách klasifikovaných tříd (viz tabulky 17-19 v příloze 1) při použití různých klasifikačních metod (viz grafy 4-6). Přestože podle klasických metod hodnocení přesnosti, založených na analýze validačních ploch a chybové matici, dosahovaly poslední tři klasifikační metody velmi dobrých výsledků, rozdíly v rozloze jednotlivých ploch u různých metod někdy přesáhly 10 % plochy území. U Hraniční louky a Alfrédky byly klasifikované rozlohy tříd výrazně konzistentnější než u Jakšína. U všech tří lokalit jsou patrné podobné trendy v případě smrku a z grafů vyplývá, že nejvíce podobné si byly metody RF a SVM. K největším rozdílům dochází v rozlohách vegetačních tříd u Jakšína, a to zejména u tříd brusnice borůvky (*Vaccinium myrtillus*), třtiny chloupkaté (*Calamagrostis villosa*) a smrku ztepilého (*Picea abies*).


graf 4: klasifikované rozlohy tříd různými klasifikačními metodami na Hraniční louce
(MLC=maximální věrohodnost, RF=Random forest, SVM=Support vector machine, OBJ=objektová klasifikace)



graf 5: klasifikované rozlohy tříd různými klasifikačními metodami na Alfrédce
(MLC=maximální věrohodnost, RF=Random forest, SVM=Support vector machine, OBJ=objektová klasifikace)



graf 6: klasifikované rozlohy tříd různými klasifikačními metodami na Jakšíně
(MLC=maximální věrohodnost, RF=Random forest, SVM=Support vector machine, OBJ=objektová klasifikace)



Z důvodu rozdílů mezi rozlohami tříd byla zpracována analýza překryvu, při které byly překryty mapy, vzniklé za použití různých klasifikačních metod. Na základě tohoto překryvu bylo určeno, v jak velké části území se jednotlivé třídy v překryvu shodují a které třídy byly nejvíce zaměňovány (viz graf 1-3 a přílohy 8-14). Nejlepší shody výsledků klasifikací (76 %) bylo dosaženo překryvem pixelových klasifikací RF a SVM. Při porovnávání OBIA a klasifikace RF na Hraniční louce bylo dosaženo shody v ploše 66 %, což je také relativně uspokojivý výsledek. Po odstranění všech pixelů, v jejichž rozřazení se klasifikační metody neshodují, je stále možné u obou překryvů rozlišit kde se nachází porosty jednotlivých druhů a většina neshod se týká okrajů ploch s dominantním výskytem jednoho druhu nebo záměny smrku (*Picea abies*), borovice kleč (*Pinus mugo*) a zastíněných ploch v okrajových částech zájmového území. Při srovnávání výsledků OBIA a klasifikace RF se velká území s nejasným druhovým porostem nachází na severozápadě, kde metoda OBIA klasifikovala místo borovice kleč (*Pinus mugo*) holou organozem a také na jihovýchodě, v nezalesněném místě mimo hlavní zájmové území, kde mohou růst i jiné druhy než na Hraniční louce. RF a SVM dochází na obou těchto místech ke konzistentnějším výsledkům.

Při porovnávání výsledků různých klasifikačních metod na rašeliništi Alfrédka bylo dosaženo nejlepší shody porovnáním pixelových metod RF a SVM, které se shodovaly na 72 % plochy. O něco nižší shody, 61 %, bylo dosaženo mezi metodou OBIA a metodou RF a mezi metodou OBIA a metodou SVM byla shoda jen na 58 % plochy. I při porovnávání podílů jednotlivých tříd na rozloze při využití

různých metod bylo zjištěno, že vzájemně jsou si podobnější výsledky pixelových klasifikačních metod než kterýkoliv z nich výsledku metody OBIA. Na území Alfrédky byly nejvýznamnější rozdíly v klasifikované rozloze smrku (*Picea abies*), borovice kleč (*Pinus mugo*) a rašeliníku (*Sphagnum* sp.).

Mnohem výrazněji se stejný fenomén projevil při klasifikaci Jakšína. Zde se na velkém území neshodují objektová a pixelové klasifikační metody v určení, zda jde o porost brusnice borůvky (*Vaccinium myrtillus*) nebo smrku (*Picea abies*). Shoda mezi metodou OBIA a metodou RF je v ploše jen 38 %, ale pixelové metody RF a SVM se shodují z 57 %. Z analýz separability trénovacích ploch se zdá pravděpodobné, že tato neshoda je způsobena nedostatečnou spektrální separabilitou tříd brusnice borůvky (*Vaccinium myrtillus*) a smrku ztepilého (*Picea abies*) při trénování. Z nafocených snímků také není zřejmé, kde by se mohlo jednat o porost *Vaccinium myrtillus* a kde o semenáčky smrku (*Picea abies*), takže není možné rozlišit, zda jsou blíže skutečnosti výsledky pixelových metod nebo objektové klasifikační metody. Na základě těchto výsledků se domnívám, že mapy vegetačního pokryvu Jakšína pravděpodobně není možné použít k bližšímu než orientačnímu hodnocení momentálního stavu lokality. Nicméně nepřesnost klasifikací se na validačních plochách výrazně neprojevila a výsledky hodnocení přesnosti s jejich pomocí jsou velmi dobré. V každém případě je výhodou, že multispektrální data byla pořízena před revitalizací rašeliniště. Z výsledků vyplynulo, že je potřeba v terénu dosbírat další botanická data. Protože vegetace se mění s jistou prodlevou po provedení revitalizačních opatření, bude možné data pro jednotlivé třídy dosbírat v následující sezóně a výslednou mapu zpřesnit. To platí případně i pro ostatní dvě lokality.

Výsledky klasifikací mohlo ovlivnit několik skutečností. První z nich jsou vstupní data – jak obrazová data, tak vegetační data nasbíraná v terénu (trénovací/validační) plochy. Botanická data nasbíraná botaniky přímo v terénu, nemohla být v rámci bakalářské práce ovlivněna ani optimalizována. Jejich množství bylo malé a některé třídy nebyly dostatečně zastoupeny. Jedná se zejména o rašelinu na Alfrédce, ale také třtinu chloupkatou na Alfrédce i na Jakšíně nebo holou organozemě na Hraniční louce. Největší počet trénovacích pixelů byl použit na Hraniční louce, kde bylo také dosaženo nejkonzistentnějších výsledků klasifikací. Na všech třech územích byl také zaznamenán vliv počtu trénovacích pixelů na výsledné přesnosti klasifikací a konzistenci různých metod. Tento trend je však také ovlivněn menší rozlohou trénovacích ploch zaměřených v terénu, které vykazují v průměru nižší separabilitu, a větší rozlohou trénovacích ploch doplněných z ortomozaiky, jejichž separabilita je vyšší a dají se rozlišit i pouhým okem. Domnívám se však i přesto, že zaměřením dalších trénovacích polygonů tříd vegetačního pokryvu v terénu by bylo možné přesnost klasifikace a konzistenci jednotlivých metod výrazně zvýšit. Tento úsudek platí zejména pro Jakšíň, ale také pro Alfrédku.

Dalším problémem mohou být nepřesnosti a chyby v trénovacích plochách, z nichž některé byly odhaleny, ale další mohly zůstat v trénovacím datasetu. Jak bylo zjištěno při prvních pokusech s klasifikací metodou MLC, jediná chybná trénovací plocha může výsledky klasifikace výrazně ovlivnit a může výrazně snížit separabilitu mezi třídami vegetačního pokryvu. Podezřelé z takových chyb jsou především trénovací plochy pro třídu brusnice borůvky (*Vaccinium myrtillus*) na lokalitě Jakšín, kde zjištěná velice nízká separabilita vůči smrku (*Picea abies*) poukazuje na možnou přítomnost smrkových semenáčků v některých plochách použitých pro trénování brusnice borůvky (*Vaccinium myrtillus*). To vyplynulo i na základě konzultace výsledků s Mgr. Vierou Horákovou z KRNAP, která vegetační data pořizovala. Tato možnost se jeví jako pravděpodobná zejména s ohledem na to, že na území rašeliniště Alfrédka, kde se obě třídy taktéž hojně vyskytují, se je podařilo úspěšně odlišit. Jiným příkladem může být třída holé organozemě na lokalitě Hraniční louky, kde mohlo dojít k chybě díky rozdílnému termínu sběru obrazových dat a dat z terénu. Holá půda může být periodicky zaplavována při vyšším vodním stavu nebo zarůstána a byla klasifikována velmi nepřesně, což by mohlo znamenat, že v době snímání na stejném místě mohl být jiný typ krajinného pokryvu. Rozpoznatelnost této třídy ze snímků lidským okem je velmi problematická.

Další možné ovlivnění klasifikací a jejich přesností mohla ovlivnit kvalita snímků UAS a podmínky, za kterých byly snímány. Nižší přesnost klasifikace Jakšina může být také způsobena oblačností, která zamezila přístupu většího množství slunečního svitu na povrch Země a díky tomu zhoršila separabilitu jednotlivých tříd. Silný vítr, přítomný v den snímání, který způsobil problémy na okrajích ortomozaiky a některé snímky nebylo možné použít, mohl také snížit celkovou kvalitu ortomozaiky. Bezvětrné a stabilně slunečné počasí by tedy mohlo vést k pořízení kvalitnějšího obrazových dat a k lepším klasifikačním výsledkům.

Stejně tak by bylo možné celkovou přesnost klasifikace a konzistenci jednotlivých metod zlepšit přidáním informace do obrazových dat. První možností by bylo zvýšení počtu spektrálních pásem, což by vyžadovalo použití multispektrální kamery s větším počtem pásem nebo hyperspektrální kamery. Druhou možností by bylo použití multitemporálního snímání, které by mohlo přidat další klasifikovatelné ortomozaiky a bylo by možné dospět k přesnějšímu zmapování vegetačních tříd. Nevýhodou obou přístupů je větší finanční náročnost, multitemporální snímání je navíc náročnější i časově a logisticky. Jak už bylo také zmíněno výše, rašeliniště jsou dynamický ekosystém, který by vyžadoval při multitemporálním přístupu počítat s možnými změnami krajinného pokryvu a zejména vodního režimu, který výsledné klasifikace ovlivňuje.

Stojí také za zmínku, jak významné odlišnosti byly zaznamenány mezi dvěma různými typy horských rašelinišť, na které se zkoumané plochy dělí. Hraniční louka, která je skutečným původním

otevřeným vrchovištěm, je v nejlepším stavu a celá je porostlá vegetací typickou pro rašeliniště. Neroste zde brusnice borůvka (*Vaccinium myrtillus*) a smrk zabírá menší část jejího území a nerozšiřuje se mimo řídký lesní porost na okrajích zájmového území. Většina nezalesněného území Hraniční louky je porostlá suchopýrkem trsnatým (*Trichophorum cespitosum*). Proti tomu Alfrédka a Jakšín, patřící mezi lesní rašeliniště, jsou z velké části porostlé semenáčky smrku ztepilého (*Picea abies*) nebo brusnicí borůvkou a neroste zde téměř žádná borovice kleč (*Pinus mugo*). Typická vegetace rašelinišť zabírá jen menší části těchto území uprostřed odlesněných ploch. V souvislosti s výsledky klasifikace je důležité poznamenat, že Hraniční louka vykazovala nejvyšší přesnost klasifikace metodou OBIA i shodu v překryvech výsledných map vegetačního pokryvu. Je tedy možné, že lesní rašeliniště jako Alfrédka a Jakšín jsou obtížněji klasifikovatelné. Protože ale výzkum komplikovaly i další faktory, jako třeba počasí (Jakšín, oblačnost) nebo velikost trénovacích ploch (Alfrédka), je možné, že druh rašeliniště nemá na výsledky vliv.

Klasifikační výsledky dosažené pro území Hraniční louky a Alfrédky považují za uspokojivé. Nejvyšší dosažené celkové přesnosti klasifikací jsou u všech ploch srovnatelné s literaturou nebo dokonce překonávají přesnosti v ní zmíněné (viz tabulka 17). Celková přesnost map krajinného pokryvu, vytvořených klasifikací OBIA, u všech zájmových území přesahuje 90 %, což je více, než dosahuje například Marcinkowska et al. (2014) při klasifikaci rostlinných společenstev v západních Krkonoších nebo Kupková et al. (2017) při klasifikaci typu vegetačního pokryvu v krkonošské tundře. Stejně tak přesnost výsledků překonává přesnost řady zahraničních výzkumů (Liu et al., 2018; Pande-Chhetri et al., 2017). Tento mimořádně dobrý výsledek je o to významnější s ohledem na to, že tato práce pracuje s jednotlivými druhy, ne se zobecněnými třídami krajinného pokryvu jako většina literatury. Výsledky mohly být natolik přesné jistě i díky pásmům NIR a RE, která jsou na rozlišení vegetace velmi užitečná, ale také díky výhodám UAS, které umožňuje vyšší prostorové rozlišení než některé jiné senzory využívané v literatuře. I dosaženou prostorovou shodu v případě klasifikačních výstupů SVM a RF pro Alfrédku (na 72 % území) a Hraniční louku (dokonce na 76 % území) lze považovat za velmi dobrou.

Tabulka 17: Srovnání přesnosti několika výzkumů v porovnání s touto prací

zájmové území	výzkum	typ zkoumané vegetace	obrazová data	klasifikační metoda	počet tříd	průměrná přesnost klasifikace
Krkonoše	Marcinkowska et al. (2014)	všechna společenstva	APEX	pixelově orientovaná SVM	15	79 %
	Zagajewski et al. (2021)	lesní druhy	Sentinel-2	pixelově orientovaná SVM	4	87 %
	Kupková et al. (2017)	společenstva v tundře	AISA dual	pixelově orientovaná SVM	11	84 %
	Kupková et al. (2020)	druhy v rašeliništi	UAS	objektově orientovaná SVM	14	86 %
Německo	Knoth et al. (2013)	druhy v rašeliništi	UAS	objektově orientovaná SVM	4	91 %
Florida, USA	Pande-Chhetri et al. (2017)	druhy v mokřadu	UAS	objektově orientovaná SVM	12	71 %
Quebec, Kanada	Chabot & Bird (2013)	typy krajinného pokryvu v mokřadu	UAS	maximální věrohodnost	3	92 %
Florida, USA	Liu et al. (2018)	společenstva v mokřadu	UAS	FCN (fully convolutional network)	6	84 %
Německo	Beyer et al. (2019)	druhy v mokřadu	UAS	pixelově orientovaná RF	11	89 %
Krkonoše	tato práce	druhy v horských rašeliništích	UAS	objektově orientovaná SVM	10	96 %

Jak ale už bylo naznačeno výše, vypočtená celková přesnost výstupů klasifikace je vázána na trénovací a validační plochy a nemusí být vždy konzistentní v celém klasifikačním výstupu. Porovnávání výsledných map ukázalo, že přesnost je potřeba hodnotit komplexněji (než pouze číselně na základě běžně používaných ukazatelů, jimiž jsou celková přesnost, uživatelská a zpracovatelská přesnost) a v rámci ploch bude nejspíš v některých místech a i celkově (zejména pro Jakšín) nižší než vypočtených 96 %. Zagajewski et al. (2021) ve svém výzkumu porovnávali svou klasifikaci lesních porostů na satelitních snímcích z družice Sentinel-2 s pravděpodobně přesnější klasifikací části zájmového území na hyperspektrálních snímcích senzoru APEX a výsledky se shodovaly na více než 70 % plochy u všech tříd. To by naznačovalo o něco větší spolehlivost než u mého výzkumu, i když jen pro 4 třídy na úrovni

druhů. Přesnějšího srovnání výzkumu s literaturou by mohlo být dosaženo lepší reprezentativností validačních ploch. Vzhledem k vzájemné blízkosti trénovacích a validačních ploch (viz popis tvorby validačních polygonů) výslednou shodu mohla ovlivnit i prostorová závislost trénovacích a validačních ploch a pokud by nezávisle na sobě trénovací i validační plochy pokrývaly reprezentativně celé území, bylo by možné dojít k jistějšímu měření přesnosti klasifikací. Takovou možnost ovšem během výzkumu znemožňovalo omezené množství terénních dat. Navíc experimenty prováděné týmem Tilspec a skupinou studentů prokázaly, že rozdíl ve výsledcích hodnocení přesnosti získaných s použitím polygonů a bodů v případě dat se stejným prostorovým a spektrálním rozlišením pro plochu Bílé louky v Krkonoších (též klasifikace v úrovni druhů) je maximálně v řádech nižších procent (do cca 2 %) (Kupková et al., 2022b).

Dle hodnocení přesnosti, založeného na validačních polygonech, bylo navíc u většiny vegetačních tříd dosaženo srovnatelné přesnosti s literaturou. Například pro ostřici bažinnou (*Carex limosa*) dosáhla OBIA na Hraniční louce uživatelské přesnosti 78 %, což je stejně, jako uvádí Kupková et al. (2020). Beyer et al. (2019) klasifikovali rod *calamagrostis* s uživatelskou přesností 83 % a nejlepší přesnosti pro druh *Calamagrostis villosa* (třtina chloupkatá) v této práci bylo dosaženo na Alfrédce, a to 80 %. Lepší přesnosti také dosáhli například Kupková et al. (2020) při klasifikaci borovice kleč (*Pinus mugo*), a to uživatelské přesnosti 99 %, zatímco v této práci byla na Hraniční louce zmapována s uživatelskou přesností 95 % a na Alfrédce je 89 %. Ve stejném výzkumu je ale také dosaženo nižší přesnosti pro druh ostřice zobánkaté (*Carex rostrata*), který je klasifikován s uživatelskou přesností 81 % a v této práci je na Alfrédce dosaženo pro tento druh uživatelské přesnosti 99 %. U mnohých tříd vegetačního pokryvu by bylo možné zvýšit přesnosti, pokud by bylo k dispozici více trénovacích dat. S ohledem na dosaženou přesnost by to bylo nejvíce potřeba u třídy rašeliny na Alfrédce, pro třtinu chloupkatou na Alfrédce a na Jakšíně a brusnici borůvku na Jakšíně.

Proti většině literatury (Kupková et al., 2017; Marcinkowska et al., 2014), týkající se vegetace v KRNAPu, využívá tato práce data obrazová s vyšším prostorovým rozlišením, kterého bylo možné dosáhnout pouze s využitím UAS. Ve srovnání s dalšími studiemi (Chabot & Bird, 2013; Liu et al., 2018) také tato práce přistupuje ke klasifikaci vegetace velmi podrobně, a to na úrovni druhů, které klasifikuje s poměrně uspokojivou přesností. Výsledky této práce ukazují, že je možné mapovat výskyt jednotlivých druhů v ekosystému rašeliniště s pomocí DPZ s dobrými výsledky a do budoucna lze některé méně uspokojivé výsledky ještě zpřesnit (po dosbírání dalších botanických dat v terénu) a použít k tvorbě přesných map aktuální vegetace sledovaných rašelinišť a do budoucna pro hodnocení účinnosti revitalizace (na základě vyhodnocení změny zastoupení a prostorového rozložení vegetace z UAS multispektrálních dat pořízených za několik let).

Další potřebný výzkum na zájmových územích bude spojen s postupným hodnocení účinnosti revitalizace. Lze očekávat, že s likvidací odvodňovacích systémů například ustoupí velké porosty brusnice borůvky (*Vaccinium myrtillus*) a budou nahrazeny mokřadními druhy, které nyní zabírají menší plochy zájmových území. Pro příští mapování krajinného pokryvu bude třeba zvětšit počet trénovacích ploch a jejich velikost pro některé vegetační třídy. Domnívám se, že tato změna by mohla vést ke zlepšení přesnosti i konzistence jednotlivých klasifikačních metod. Stejnými metodami lze také v potřebných výzkumech pokračovat v budoucnu i na jiných lokalitách v koordinaci se Správou KRNP. Další možný směr pokračujících výzkumů může být testování dalších klasifikačních metod, například jiných typů OBIA.

7 Závěr

Výstupem této práce jsou mapy vegetačního pokryvu tří krkonošských rašelinišť, Hraniční louky, Alfrédka a Jakšína. Tyto mapy byly vytvořeny klasifikací multispektrálních obrazových dat z UAS na základě botanických dat nasbíraných v terénu. Při klasifikaci zájmových území byly testovány čtyři klasifikační metody, a to pixelové metody maximální věrohodnosti, Random forest, Support vector machine a objektivě orientovaná metoda Support vector machine. Nejlepších průměrných výsledků dosáhla OBIA, jejíž přesnost byla s pomocí validačních ploch u všech tří zájmových ploch 96 % a tyto výsledky považuji za velmi dobré. Kromě metody OBIA, která dosáhla velmi podobné přesnosti na všech zájmových územích, bylo dosaženo nejpřesnějších výsledků ostatních metod na Alfrédce, o něco méně přesných na Hraniční louce a nejméně přesných na Jakšíně. Jednotlivé klasifikační metody i přes naměřenou vysokou přesnost nebyly v zařazení jednotlivých pixelů úplně konzistentní, a to zejména na Jakšíně. Více než polovinu tříd se podařilo klasifikovat s vyšší přesností než 95 %, nejhoršího výsledku (35 %) bylo dosaženo pro třídu rašeliničku na lokalitě Alfrédka. Mezi další hůře klasifikované třídy patří například třtina chloupkatá (*Calamagrostis villosa*, na Alfrédce 75 %, na Jakšíně 81 %). Nejlepších výsledků bylo dosaženo na Hraniční louce, která je otevřeným vrchovištěm, nejhorší přesnost byla naměřena na Jakšíně. Vegetační pokryv Hraniční louky se výrazně lišil od Alfrédky a Jakšína, které jsou obě lesní rašeliniště.

Výsledné mapy (zejména výsledky klasifikace RF a OBIA) dosahují uspokojivé přesnosti, čímž byl splněn základní cíl práce. Práce dále otestovala vhodnost klasifikačních metod pro mapování mokřadů a bylo zjištěno, které metody dosahují nejpřesnějších výsledků. Důležitým přínosem práce je i nová metoda hodnocení přesnosti klasifikací s využitím analýzy překryvu, která dokáže doplnit klasické hodnocení klasifikace a odhalit některé nedostatky. Rozdíl ve výsledcích hodnocení prostorové shody jednotlivých klasifikačních výstupů (analýza překryvu) na Hraniční louce (nejlepší shoda) a Jakšíně

(nejhorší shoda) ukazuje, že i přes podobné výsledky v celkové přesnosti klasifikací (počítané na základě validačních ploch), nemusí být prostorová přesnost klasifikačních výstupů stejně dobrá a konzistentní v celém území. Tyto výsledky mohou pomoci dále rozvinout nové metody hodnocení přesnosti klasifikace. Pro zlepšení přesnosti klasifikace (zejména v případě rašeliniště Jakšín) lze na základě výsledků práce doporučit dosbírání dalších trénovacích a validačních ploch tak, aby měly větší rozlohu a na každém území se pro každou třídu nacházely minimálně cca čtyři plochy (v závislosti na zastoupení a rozložení dané třídy v rámci zájmového území). Z jednotlivých tříd nebyl k dispozici dostatek trénovacích dat zejména pro rašeliník, třtinu chloupkatou (*Calamagrostis villosa*) a ostřici bažinnou (*Carex limosa*). Konkrétní mapy vegetačního pokryvu (přílohy 2-7), budou zaslány botanikům do KRNAP a budou využity jako vstupní podklady pro monitoring stavu vegetace rašelinišť. Mapa pro území Jakšina bude ještě zpřesněna po dosbírání vegetačních dat v terénu.

Metody DPZ, zejména využití UAS v kombinaci s multispektrální kamerou a velmi vysokým prostorovým rozlišením v řádu centimetrů, se při zkoumání vegetačního pokryvu ukázaly být velmi efektivním způsobem mapování vegetace a jejího monitoringu, a to i na úrovni druhů. Ukázaly se také výhody spolupráce Správy KRNAP s geoinformatiky, kteří mohou v národním parku výzkum zefektivnit s použitím moderních metod.

Pro budoucí zlepšení přesností klasifikací rašelinišť doporučuji testovat další klasifikační metody, například moderní metody strojového a hlubokého učení. Stejně tak může zlepšení výsledků pomoci multitemporální snímání vícekrát v průběhu sezóny. Výsledky této práce lze dále také využít při mapování krajinného pokryvu na dalších rašeliništích v KRNAP, jehož další fáze je plánovaná v letní sezóně roku 2022.

Použitá literatura

- Alvarez-Vanhard, E., Houet, T., Mony, C., Lecoq, L., & Corpetti, T. (2020). Can UASs fill the gap between in situ surveys and satellites for habitat mapping? *Remote Sensing of Environment*, 243. <https://doi.org/10.1016/j.rse.2020.111780>
- Amani, M., & Mobasheri, M. R. (2015). A parametric method for estimation of leaf area index using landsat ETM+ data. *GIScience and Remote Sensing*, 52(4), 478–497. <https://doi.org/10.1080/15481603.2015.1055540>
- Anderson, K., & Gaston, K. J. (2013). Lightweight unmanned aerial vehicles will revolutionize spatial ecology. In *Frontiers in Ecology and the Environment* (Vol. 11, Issue 3, pp. 138–146). <https://doi.org/10.1890/120150>
- Andrštová, M. (2014). *Využití hyperspektrálních dat ke klasifikaci vegetace alpského bezlesí v Krkonoších. Diplomová práce*. Přírodovědecká fakulta Univerzity Karlovy v Praze.
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 114, pp. 24–31). Elsevier B.V. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Beyer, F., Jurasinski, G., Couwenberg, J., & Grenzdörffer, G. (2019). Multisensor data to derive peatland vegetation communities using a fixed-wing unmanned aerial vehicle. *International Journal of Remote Sensing*, 40(24), 9103–9125. <https://doi.org/10.1080/01431161.2019.1580825>
- Bhatnagar, S., Gill, L., Regan, S., Waldren, S., & Ghosh, B. (2021). A nested drone-satellite approach to monitoring the ecological conditions of wetlands. *ISPRS Journal of Photogrammetry and Remote Sensing*, 174, 151–165. <https://doi.org/10.1016/j.isprsjprs.2021.01.012>
- Blaschke, T. (2010). Object based image analysis for remote sensing. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 65, Issue 1, pp. 2–16). <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Boon, M. A., Greenfield, R., & Tesfamichael, S. (2016). Wetland assessment using unmanned aerial vehicle (UAS) photogrammetry. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 41, 781–788. <https://doi.org/10.5194/isprsarchives-XLI-B1-781-2016>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32.

- Canada Centre for Mapping and Earth Observation. (2016). *Fundamentals of Remote Sensing*.
- Cao, J., Leng, W., Liu, K., Liu, L., He, Z., & Zhu, Y. (2018). Object-Based mangrove species classification using unmanned aerial vehicle hyperspectral images and digital surface models. *Remote Sensing*, *10*(1). <https://doi.org/10.3390/rs10010089>
- Chabot, D., & Bird, D. M. (2013). Small unmanned aircraft: Precise and convenient new tools for surveying wetlands. *Journal of Unmanned Vehicle Systems*, *1*(1), 15–24. <https://doi.org/10.1139/juvs-2013-0014>
- Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 92, pp. 79–97). Elsevier B.V. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- Cruzan, M. B., Weinstein, B. G., Grasty, M. R., Kohn, B. F., Hendrickson, E. C., Arredondo, T. M., & Thompson, P. G. (2016). Small Unmanned Aerial Vehicles (Micro-UASs, Drones) in Plant Ecology. *Applications in Plant Sciences*, *4*(9), 1600041. <https://doi.org/10.3732/apps.1600041>
- Csillik, O., Cherbini, J., Johnson, R., Lyons, A., & Kelly, M. (2018). Identification of citrus trees from unmanned aerial vehicle imagery using convolutional neural networks. *Drones*, *2*(4), 1–16. <https://doi.org/10.3390/drones2040039>
- Čvančara, A. (1990). Vaccinium L. – borůvka. In S. Hejný, B. Slavík, L. Hrouda, & V. Skalický (Eds.), *Květena České republiky 2* (pp. 503–505). Academia.
- DJI. (2019). *Phantom 4 Multispectral user manual*. <https://www.dji.com/p4-multispectral/video>
- Dobrovolný Petr. (1998). *Dálkový průzkum Země. Digitální zpracování obrazu*. Přírodovědecká fakulta Masarykovy Univerzity, katedra Geografie.
- Du, B., Mao, D., Wang, Z., Qiu, Z., Yan, H., Feng, K., & Zhang, Z. (2021). Mapping Wetland Plant Communities Using Unmanned Aerial Vehicle Hyperspectral Imagery by Comparing Object/Pixel-Based Classifications Combining Multiple Machine-Learning Algorithms. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *14*, 8249–8258. <https://doi.org/10.1109/JSTARS.2021.3100923>
- Duro, D. C., Franklin, S. E., & Dubé, M. G. (2012). A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, *118*, 259–272. <https://doi.org/10.1016/j.rse.2011.11.020>

- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment* 80, 80, 185–201. www.elsevier.com/locate/rse
- Foody, G. M. (2020). Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, 239. <https://doi.org/10.1016/j.rse.2019.111630>
- Fraser, L. H., & Keddy, P. A. (2005). *The World's Largest Wetlands: Ecology and conservation*. Cambridge University Press.
- Fraser, R. H., Olthof, I., Lantz, T. C., & Schmitt, C. (2016). UAS photogrammetry for mapping vegetation in the low-Arctic. *Arctic Science*, 2(3), 79–102. <https://doi.org/10.1139/as-2016-0008>
- Fu, B., Liu, M., He, H., Lan, F., He, X., Liu, L., Huang, L., Fan, D., Zhao, M., & Jia, Z. (2021). Comparison of optimized object-based RF-DT algorithm and SegNet algorithm for classifying Karst wetland vegetation communities using ultra-high spatial resolution UAS data. *International Journal of Applied Earth Observation and Geoinformation*, 104. <https://doi.org/10.1016/j.jag.2021.102553>
- Harris geospatial. (2022). *Example-Based Classification*. [Www.l3harrisgeospatial.com/docs/Example_based_classification.html](http://www.l3harrisgeospatial.com/docs/Example_based_classification.html).
- 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.
- Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725–749. <https://doi.org/10.1080/01431160110040323>
- Hung, C., Xu, Z., & Sukkarieh, S. (2014). Feature learning based approach for weed classification using high resolution aerial images from a digital camera mounted on a UAS. *Remote Sensing*, 6(12), 12037–12054. <https://doi.org/10.3390/rs61212037>
- Jarocińska, A. M., Kacprzyk, M., Marcinkowska-Ochtyra, A., Ochtyra, A., Zagajewski, B., & Meuleman, K. (2016). The application of APEX images in the assessment of the state of non-forest vegetation in the Karkonosze Mountains. *Miscellanea Geographica*, 20(1), 21–27. <https://doi.org/10.1515/mgrsd-2016-0009>
- Jelének, J., Kupková, L., Zagajewski, B., Březina, S., Ochtyra, A., & Marcinkowska, A. (2014). Laboratory and image spectroscopy for evaluating the biophysical state of meadow vegetation in the Krkonoše National Park. *Miscellanea Geographica*, 18(2), 15–22. <https://doi.org/10.2478/mgrsd-2014-0014>

- Jensen, J. R. (2005). *Introductory Digital Image Processing: A Remote Sensing Perspective* (3rd edition). Pearson Education.
- Kaplan, G., & Avdan, U. (2018). Monthly analysis of wetlands dynamics using remote sensing data. *ISPRS International Journal of Geo-Information*, 7(10). <https://doi.org/10.3390/ijgi7100411>
- Knoth, C., Klein, B., Prinz, T., & Kleinebecker, T. (2013). Unmanned aerial vehicles as innovative remote sensing platforms for high-resolution infrared imagery to support restoration monitoring in cut-over bogs. *Applied Vegetation Science*, 16(3), 509–517. <https://doi.org/10.1111/avsc.12024>
- Kolář Jan, Halounová Lena, & Pavelka Karel. (2000). *Dálkový průzkum Země. Skripta*. ČVUT.
- Kupková et al. (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.)*.
- Kupková, L., Červená, L., Potůčková, M., Lysák, J., Šašková, M., Šrollerů, A., Klinerová, T., Bobek, P., & Müllerová, J. (2020). *Vegetation of the tundra in the Krkonoše Mts.-past, present and future, Annual Report 2020*.
- 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>
- Lehmann, J. R. K., Nieberding, F., Prinz, T., & Knoth, C. (2015). Analysis of unmanned aerial system-based CIR images in forestry-a new perspective to monitor pest infestation levels. *Forests*, 6(3), 594–612. <https://doi.org/10.3390/f6030594>
- Lendzioch, T., Langhammer, J., Vlček, L., & Minařík, R. (2021). Mapping the groundwater level and soil moisture of a montane peat bog using UAS monitoring and machine learning. *Remote Sensing*, 13(5), 1–30. <https://doi.org/10.3390/rs13050907>
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2015). *Remote sensing and image interpretation* (7th ed.). Wiley.
- Liu, H., Zhang, F., Zhang, L., Lin, Y., Wang, S., & Xie, Y. (2020). UNVI-based time series for vegetation discrimination using separability analysis and random forest classification. *Remote Sensing*, 12(3). <https://doi.org/10.3390/rs12030529>

- Liu, T., Abd-Elrahman, A., Morton, J., & Wilhelm, V. L. (2018). Comparing fully convolutional networks, random forest, support vector machine, and patch-based deep convolutional neural networks for object-based wetland mapping using images from small unmanned aircraft system. *GIScience and Remote Sensing*, 55(2), 243–264. <https://doi.org/10.1080/15481603.2018.1426091>
- Lu, B., & He, Y. (2017). Species classification using Unmanned Aerial Vehicle (UAS)-acquired high spatial resolution imagery in a heterogeneous grassland. *ISPRS Journal of Photogrammetry and Remote Sensing*, 128, 73–85. <https://doi.org/10.1016/j.isprsjprs.2017.03.011>
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823–870. <https://doi.org/10.1080/01431160600746456>
- Manfreda, S., McCabe, M. F., Miller, P. E., Lucas, R., Madrigal, V. P., Mallinis, G., Dor, E. ben, Helman, D., Estes, L., Ciraolo, G., Müllerová, J., Tauro, F., de Lima, M. I., de Lima, J. L. M. P., Maltese, A., Frances, F., Caylor, K., Kohv, M., Perks, M., ... Toth, B. (2018). On the use of unmanned aerial systems for environmental monitoring. In *Remote Sensing* (Vol. 10, Issue 4). MDPI AG. <https://doi.org/10.3390/rs10040641>
- Marcinkowska, A., Zagajewski, B., Ochtyra, A., Jarocińska, A., Raczko, E., Kupková, L., Stych, 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>
- Matese, A., Toscano, P., di Gennaro, S. F., Genesio, L., Vaccari, F. P., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R., & Gioli, B. (2015). Intercomparison of UAS, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*, 7(3), 2971–2990. <https://doi.org/10.3390/rs70302971>
- Meneguzzo, D. M., Liknes, G. C., & Nelson, M. D. (2013). Mapping trees outside forests using high-resolution aerial imagery: A comparison of pixel- and object-based classification approaches. *Environmental Monitoring and Assessment*, 185(8), 6261–6275. <https://doi.org/10.1007/s10661-012-3022-1>
- Meng, X., Shang, N., Zhang, X., Li, C., Zhao, K., Qiu, X., & Weeks, E. (2017). Photogrammetric UAS mapping of terrain under dense coastal vegetation: An object-oriented classification ensemble algorithm for classification and terrain correction. *Remote Sensing*, 9(11). <https://doi.org/10.3390/rs9111187>

- Michez, A., Piégay, H., Jonathan, L., Claessens, H., & Lejeune, P. (2016). Mapping of riparian invasive species with supervised classification of Unmanned Aerial System (UAS) imagery. *International Journal of Applied Earth Observation and Geoinformation*, 44, 88–94. <https://doi.org/10.1016/j.jag.2015.06.014>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 66, Issue 3, pp. 247–259). <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Mthembu, L., & Marwala, T. (2008). *A note on the separability index*.
- Nex, F., & Remondino, F. (2014). UAS for 3D mapping applications: A review. In *Applied Geomatics* (Vol. 6, Issue 1, pp. 1–15). Springer Verlag. <https://doi.org/10.1007/s12518-013-0120-x>
- Nitze, I., Barrett, B., & Cawkwell, F. (2015). Temporal optimisation of image acquisition for land cover classification with random forest and MODIS time-series. *International Journal of Applied Earth Observation and Geoinformation*, 34(1), 136–146. <https://doi.org/10.1016/j.jag.2014.08.001>
- NP Šumava. (2019). *O rašeliništích*. <https://life.npsumava.cz/o-vode-a-mokradech/o-raselinistich/>.
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. v., Woodcock, C. E., & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. In *Remote Sensing of Environment* (Vol. 148, pp. 42–57). Elsevier Inc. <https://doi.org/10.1016/j.rse.2014.02.015>
- Pal, M., & Mather, P. M. (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26(5), 1007–1011. <https://doi.org/10.1080/01431160512331314083>
- Pande-Chhetri, R., Abd-Elrahman, A., Liu, T., Morton, J., & Wilhelm, V. L. (2017). Object-based classification of wetland vegetation using very high-resolution unmanned air system imagery. *European Journal of Remote Sensing*, 50(1), 564–576. <https://doi.org/10.1080/22797254.2017.1373602>
- Pladias - databáze české flóry a vegetace*. (2022). [www.Pladias.Cz](http://www.pladias.cz).
- 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>

- Ramsar Convention Secretariat. (2013). The Ramsar Convention Manual: a guide to the Convention on Wetlands (Ramsar, Iran, 1971). In *6th edition*. Ramsar Convention Secretariat.
- Ramsar Sites Information Service. (2005). *Krkonošská rašeliniště*. <https://Rsis.Ramsar.Org/Ris/637>.
- Richards, J. A., & Jia, X. (2006). *Remote Sensing Digital Image Analysis* (4th ed.). Springer.
- Roubalová M. (2019). Klasifikace vybraných druhů vegetace v krkonošské tundře s využitím časové řady dat PlanetScope, diplomová práce [Přírodovědecká fakulta Univerzity Karlovy v Praze]. In *European Journal of Remote Sensing* (Vol. 50, Issue 1). <https://doi.org/10.1080/22797254.2017.1274573>
- Rydin, H., & Jeglum, J. K. (2013). *The Biology of Peatlands* (Second edition). Oxford University Press.
- Sankey, T., Donager, J., McVay, J., & Sankey, J. B. (2017). UAS lidar and hyperspectral fusion for forest monitoring in the southwestern USA. *Remote Sensing of Environment*, 195, 30–43. <https://doi.org/10.1016/j.rse.2017.04.007>
- Schmidt, K. S., & Skidmore, A. K. (2003). Spectral discrimination of vegetation types in a coastal wetland. *Remote Sensing of Environment*, 85(1), 92–108. [https://doi.org/10.1016/S0034-4257\(02\)00196-7](https://doi.org/10.1016/S0034-4257(02)00196-7)
- Shakhatreh, H., Sawalmeh, A. H., Al-Fuqaha, A., Dou, Z., Almaita, E., Khalil, I., Othman, N. S., Khreishah, A., & Guizani, M. (2019). Unmanned Aerial Vehicles (UASs): A Survey on Civil Applications and Key Research Challenges. In *IEEE Access* (Vol. 7, pp. 48572–48634). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2019.2909530>
- Skalická, A. (1988). Pinus L. – borovice. In S. Hejný, B. Slavík, J. Chrtek, P. Tomšovic, & M. Kovanda (Eds.), *Květena České socialistické republiky 1* (pp. 289–308). Academia.
- Skalická, A., & Skalický, V. (1988). Picea A. Dietr. – smrk. In Hejný S., Slavík B., Chrtek J., Tomšovic P., & Kovanda M. (Eds.), *Květena České socialistické republiky 1* (pp. 317–326). Academia.
- Sohn, Y., & Rebello, N. S. (2002). Supervised and Unsupervised Spectral Angle Classifiers. *Photogrammetric Engineering & Remote Sensing*, 68(12), 1271–1280.
- Soudková, K. (2014). *Klasifikace smrkových porostů s využitím obrazové a laboratorní spektroskopie*, Diplomová práce [Přírodovědecká fakulta Univerzity Karlovy v Praze]. www.tcpdf.org
- Správa KRNAP. (2022). *Severská rašeliniště*. <https://Www.Krnep.Cz/Severska-Raseliniste/>.

- Volf, O., Koptík, J., Obstová, L., Holá, E., Manukjanová, A., & Štechová, T. (2019). *Revitalizace mokřadů – zpracování odborné části, Závěrečná zpráva za rok 2019*.
- Wang, C., Liu, H.-Y., Zhang, Y., & Li, Y. (2014). Classification of land-cover types in muddy tidal flat wetlands using remote sensing data. *Journal of Applied Remote Sensing*, 7(1), 073457. <https://doi.org/10.1117/1.jrs.7.073457>
- Xie, Y., Sha, Z., & Yu, M. (2008). Remote sensing imagery in vegetation mapping: a review. *Journal of Plant Ecology*, 1(1), 9–23. <https://doi.org/10.1093/jpe/rtm005>
- Xu, M., Watanachaturaporn, P., Varshney, P. K., & Arora, M. K. (2005). Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3), 322–336. <https://doi.org/10.1016/j.rse.2005.05.008>
- Yan, Y., Deng, L., Liu, X. L., & Zhu, L. (2019). Application of UAS-based multi-angle hyperspectral remote sensing in fine vegetation classification. *Remote Sensing*, 11(23). <https://doi.org/10.3390/rs11232753>
- Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M., & Schirokaue, D. (2006). Object-based Detailed Vegetation Classification with Airborne High Spatial Resolution Remote Sensing Imagery. *Photogrammetric Engineering & Remote Sensing*, 72(7), 799–811.
- 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>
- Zlinszky, A., Mücke, W., Lehner, H., Briese, C., & Pfeifer, N. (2012). Categorizing wetland vegetation by airborne laser scanning on Lake Balaton and Kis-Balaton, Hungary. *Remote Sensing*, 4(6), 1617–1650. <https://doi.org/10.3390/rs4061617>

Přílohy

Seznam příloh:

- Příloha 1: Tabulky srovnávající přesnosti klasifikací
- Příloha 2: Vegetační pokryv rašeliniště Hraniční louka (objektově orientovaná klasifikace)
- Příloha 3: Vegetační pokryv rašeliniště Hraniční louka (klasifikace Random forest)
- Příloha 4: Vegetační pokryv rašeliniště Alfrédka (objektově orientovaná klasifikace)
- Příloha 5: Vegetační pokryv rašeliniště Alfrédka (klasifikace Random forest)
- Příloha 6: Vegetační pokryv rašeliniště Jakšín (objektově orientovaná klasifikace)
- Příloha 7: Vegetační pokryv rašeliniště Jakšín (klasifikace Random forest)
- Příloha 8: Tabulky výsledků analýzy překryvů
- Příloha 9: mapa Hraniční louky – překryv RF-SVM
- Příloha 10: mapa Hraniční louky – překryv OB-RF
- Příloha 11: mapa Alfrédky – překryv RF-SVM
- Příloha 12: mapa Alfrédky – překryv OB-RF
- Příloha 13: mapa Jakšína – překryv RF-SVM
- Příloha 14: mapa Jakšína – překryv OB-RF

Příloha 1: Tabulky srovnávající přesnost klasifikací

tabulka: Srovnání přesnosti klasifikačních metod a rozlohy jednotlivých tříd při použití různých klasifikačních metod na území Hraniční louky (c.p.=celková přesnost, r.=rozloha)

Hraniční louka	Maximální věrohodnost		Random forest		Support vector machine		Objektově orientovaná (SVM)	
	c.p.	r.	c.p.	r.	c.p.	r.	c.p.	r.
celková přesnost	81,06 %		89,95 %		85,27 %		96,51 %	
třída	c.p.	r.	c.p.	r.	c.p.	r.	c.p.	r.
Holá organozem	97,3 %	0,1 %	92,5 %	0,2 %	89,1 %	0,2 %	83,0 %	1,4 %
Carex limosa	61,5 %	9,9 %	81,5 %	2,9 %	59,0 %	9,7 %	89,1 %	6,9 %
Pinus mugo	77,0 %	45,0 %	88,2 %	47,2 %	78,6 %	41,3 %	96,9 %	46,7 %
Sphagnum sp.	71,3 %	6,0 %	83,8 %	1,3 %	76,9 %	1,6 %	97,8 %	1,9 %
Picea abies	73,0 %	17,3 %	83,8 %	22,9 %	77,0 %	18,9 %	94,7 %	15,2 %
Zastíněné plochy	96,5 %	7,4 %	98,3 %	8,0 %	96,4 %	9,7 %	99,7 %	9,3 %
Vysušená vegetace	85,5 %	0,5 %	92,4 %	0,8 %	93,5 %	0,8 %	97,1 %	0,7 %
Trichophorum cespitosum	90,7 %	10,8 %	93,6 %	15,8 %	91,7 %	15,6 %	97,7 %	14,7 %
Vaccinium uliginosum	80,0 %	2,8 %	78,5 %	0,6 %	83,0 %	1,4 %	99,7 %	0,7 %
Vodní plochy	96,3 %	0,2 %	97,7 %	0,4 %	96,1 %	0,6 %	98,2 %	2,6 %

tabulka: Srovnání přesnosti klasifikačních metod a rozlohy jednotlivých tříd při použití různých klasifikačních metod na území Alfrédka (c.p.=celková přesnost, r.=rozloha)

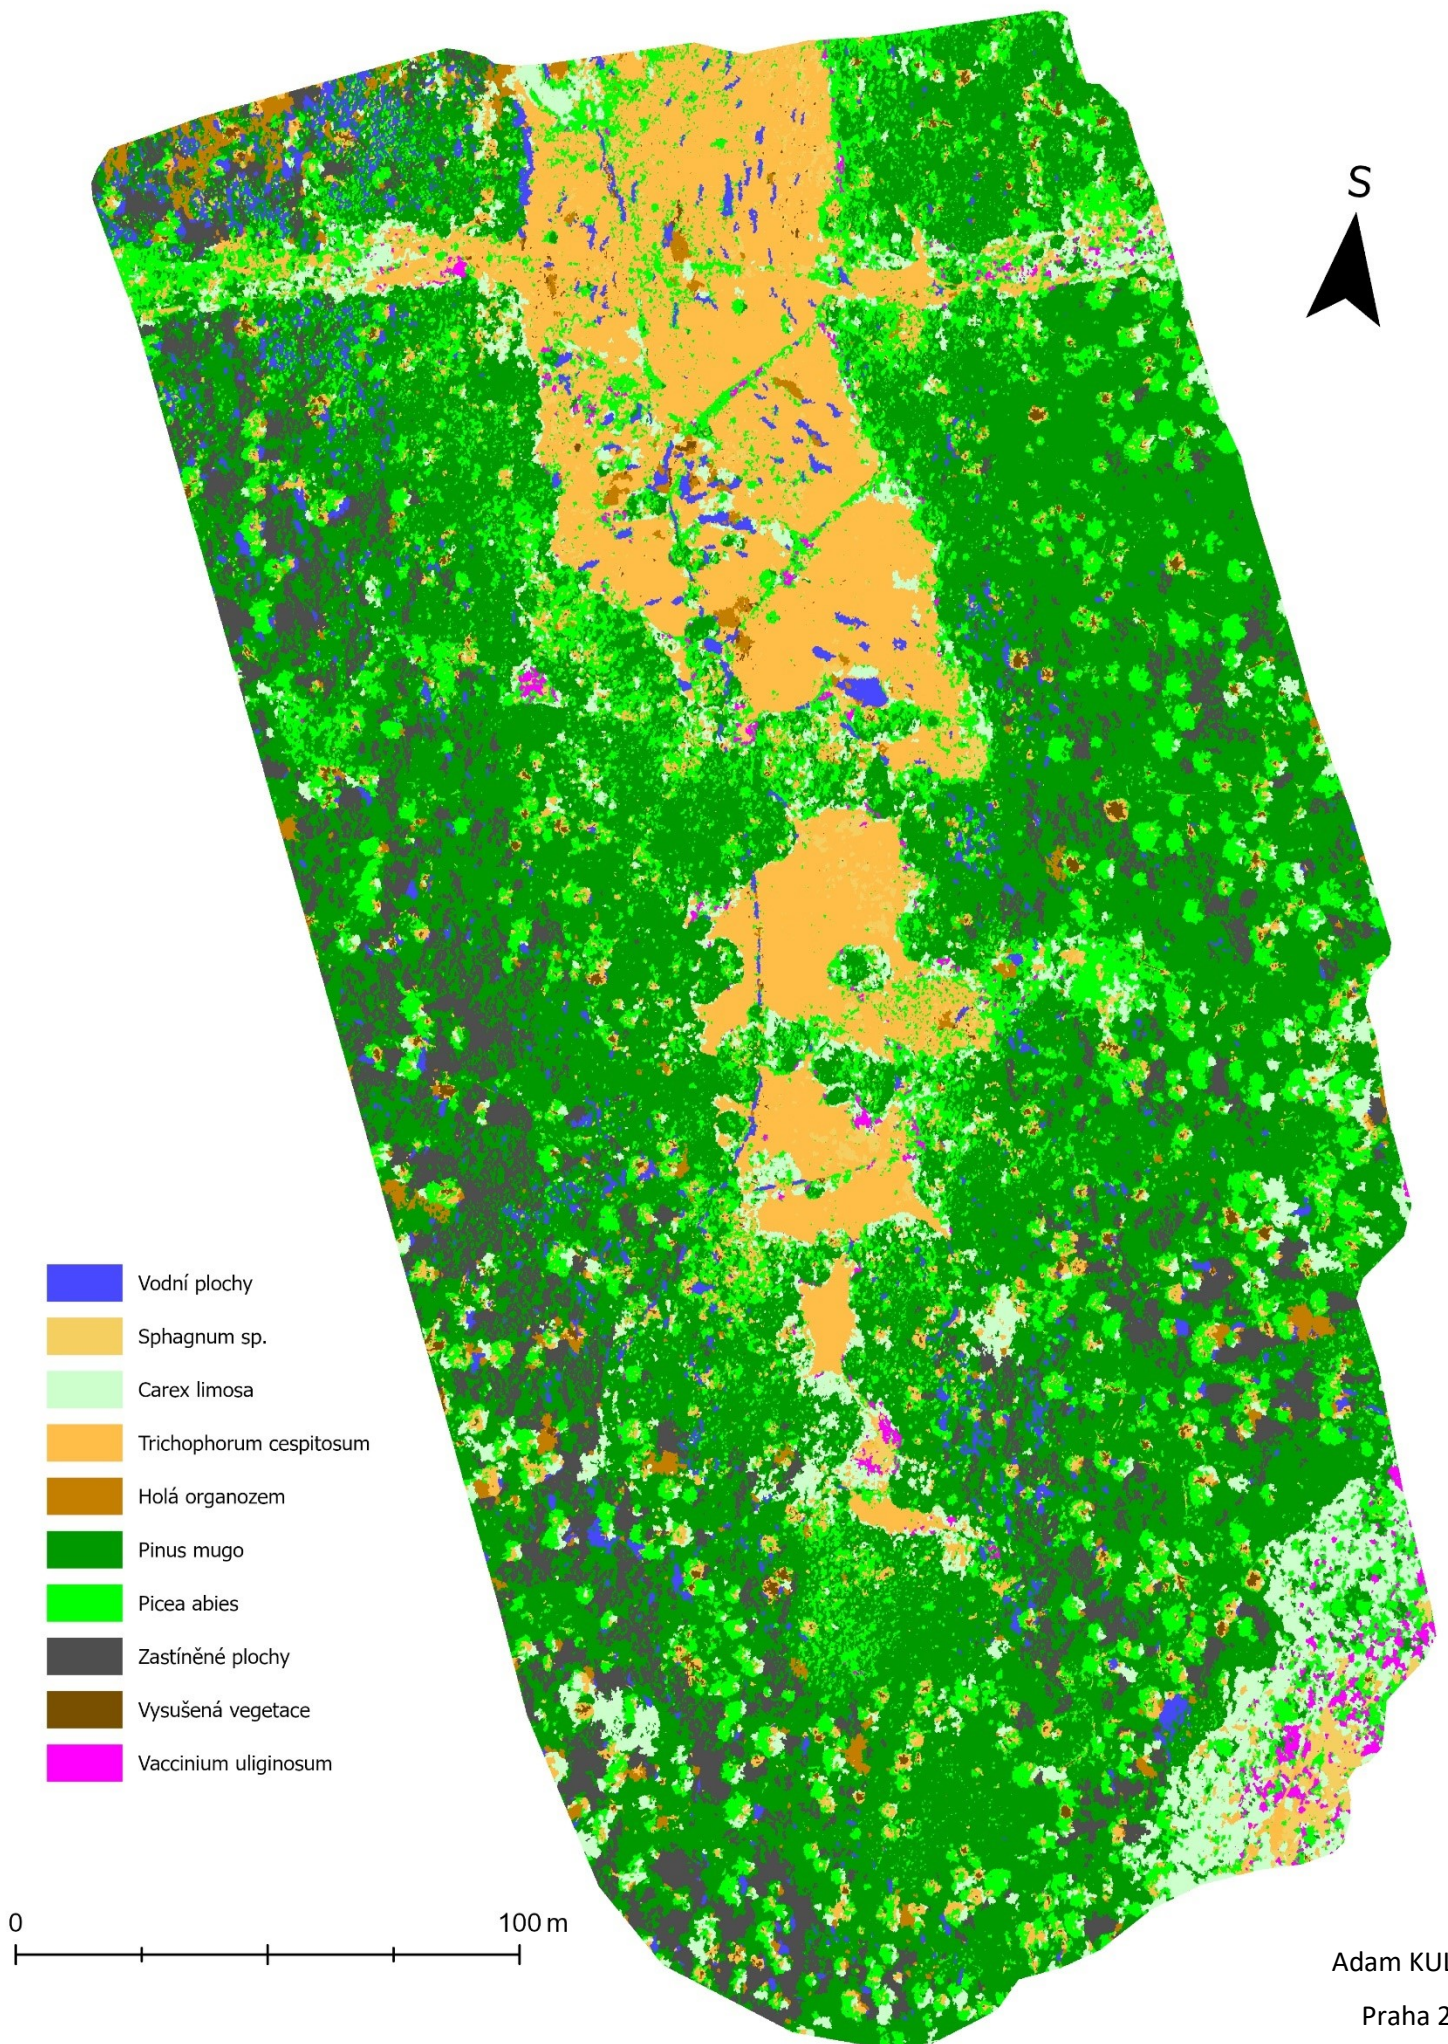
Alfrédka	Maximální věrohodnost		Random forest		Support vector machine		Objektově orientovaná (SVM)	
	c.p.	r.	c.p.	r.	c.p.	r.	c.p.	r.
celková přesnost	81,54 %		91,57 %		90,54 %		96,39 %	
třída	c.p.	r.	c.p.	r.	c.p.	r.	c.p.	r.
Vaccinium myrtillus	87,1 %	18,0 %	91,2 %	17,0 %	90,7 %	20,2 %	99,7 %	18,1 %
Calamagrostis villosa	31,5 %	9,3 %	36,9 %	1,4 %	37,9 %	1,6 %	74,6 %	4,9 %
Eriophorum vaginatum	66,4 %	6,1 %	74,7 %	3,4 %	60,4 %	2,1 %	94,3 %	10,2 %
Molinia caerulea	64,4 %	5,8 %	74,1 %	1,2 %	78,1 %	2,5 %	86,4 %	1,4 %
Sphagnum sp.	22,1 %	1,3 %	0,0 %	0,8 %	0,0 %	0,0 %	35,0 %	10,5 %
Picea abies	88,3 %	2,9 %	80,0 %	4,8 %	89,3 %	2,9 %	92,9 %	1,9 %
Zastíněné plochy	77,8 %	34,9 %	91,8 %	52,0 %	89,2 %	48,1 %	95,8 %	35,0 %
Vysušené vegetace	99,3 %	10,5 %	98,6 %	12,2 %	98,1 %	13,5 %	100,0 %	8,9 %
Vaccinium uliginosum	99,1 %	10,9 %	99,6 %	6,6 %	99,6 %	8,5 %	99,9 %	7,9 %
Vodní plochy	99,0 %	0,4 %	97,8 %	0,6 %	97,8 %	0,6 %	99,7 %	1,2 %

tabulka: Srovnání přesnosti klasifikačních metod a rozlohy jednotlivých tříd při použití různých klasifikačních metod na území Jakšina (c.p.=celková přesnost, r.=rozloha)

Jakšín	Maximální věrohodnost		Random forest		Support vector machine		Objektově orientovaná (SVM)	
	c.p.	r.	c.p.	r.	c.p.	r.	c.p.	r.
celková přesnost	74,99 %		82,65 %		80,77 %		95,76 %	
Vaccinium myrtillus	66,1 %	34,2 %	68,2 %	18,3 %	63,0 %	16,3 %	92,1 %	42,3 %
Calamagrostis villosa	47,4 %	2,6 %	70,2 %	0,9 %	53,5 %	0,3 %	80,8 %	17,0 %
Eriophorum vaginatum	53,6 %	1,1 %	52,3 %	0,8 %	42,3 %	0,8 %	100,0 %	0,5 %
Molinia caerulea	77,7 %	15,4 %	71,6 %	11,5 %	69,3 %	8,1 %	93,4 %	4,9 %
Sphagnum sp.	87,2 %	6,5 %	68,1 %	9,8 %	81,9 %	9,4 %	90,2 %	11,3 %
Picea abies	75,4 %	30,7 %	87,5 %	49,6 %	83,1 %	55,8 %	97,5 %	20,1 %
Zastíněné plochy	98,5 %	1,6 %	97,5 %	1,0 %	99,3 %	1,9 %	100,0 %	0,6 %
Vysušené vegetace	99,1 %	6,5 %	99,8 %	5,5 %	99,4 %	5,5 %	99,9 %	2,2 %
Vaccinium uliginosum	83,4 %	1,2 %	82,0 %	2,0 %	62,8 %	1,2 %	100,0 %	0,3 %
Vodní plochy	100,0 %	0,0 %	100,0 %	0,6 %	100,0 %	0,8 %	98,6 %	0,8 %

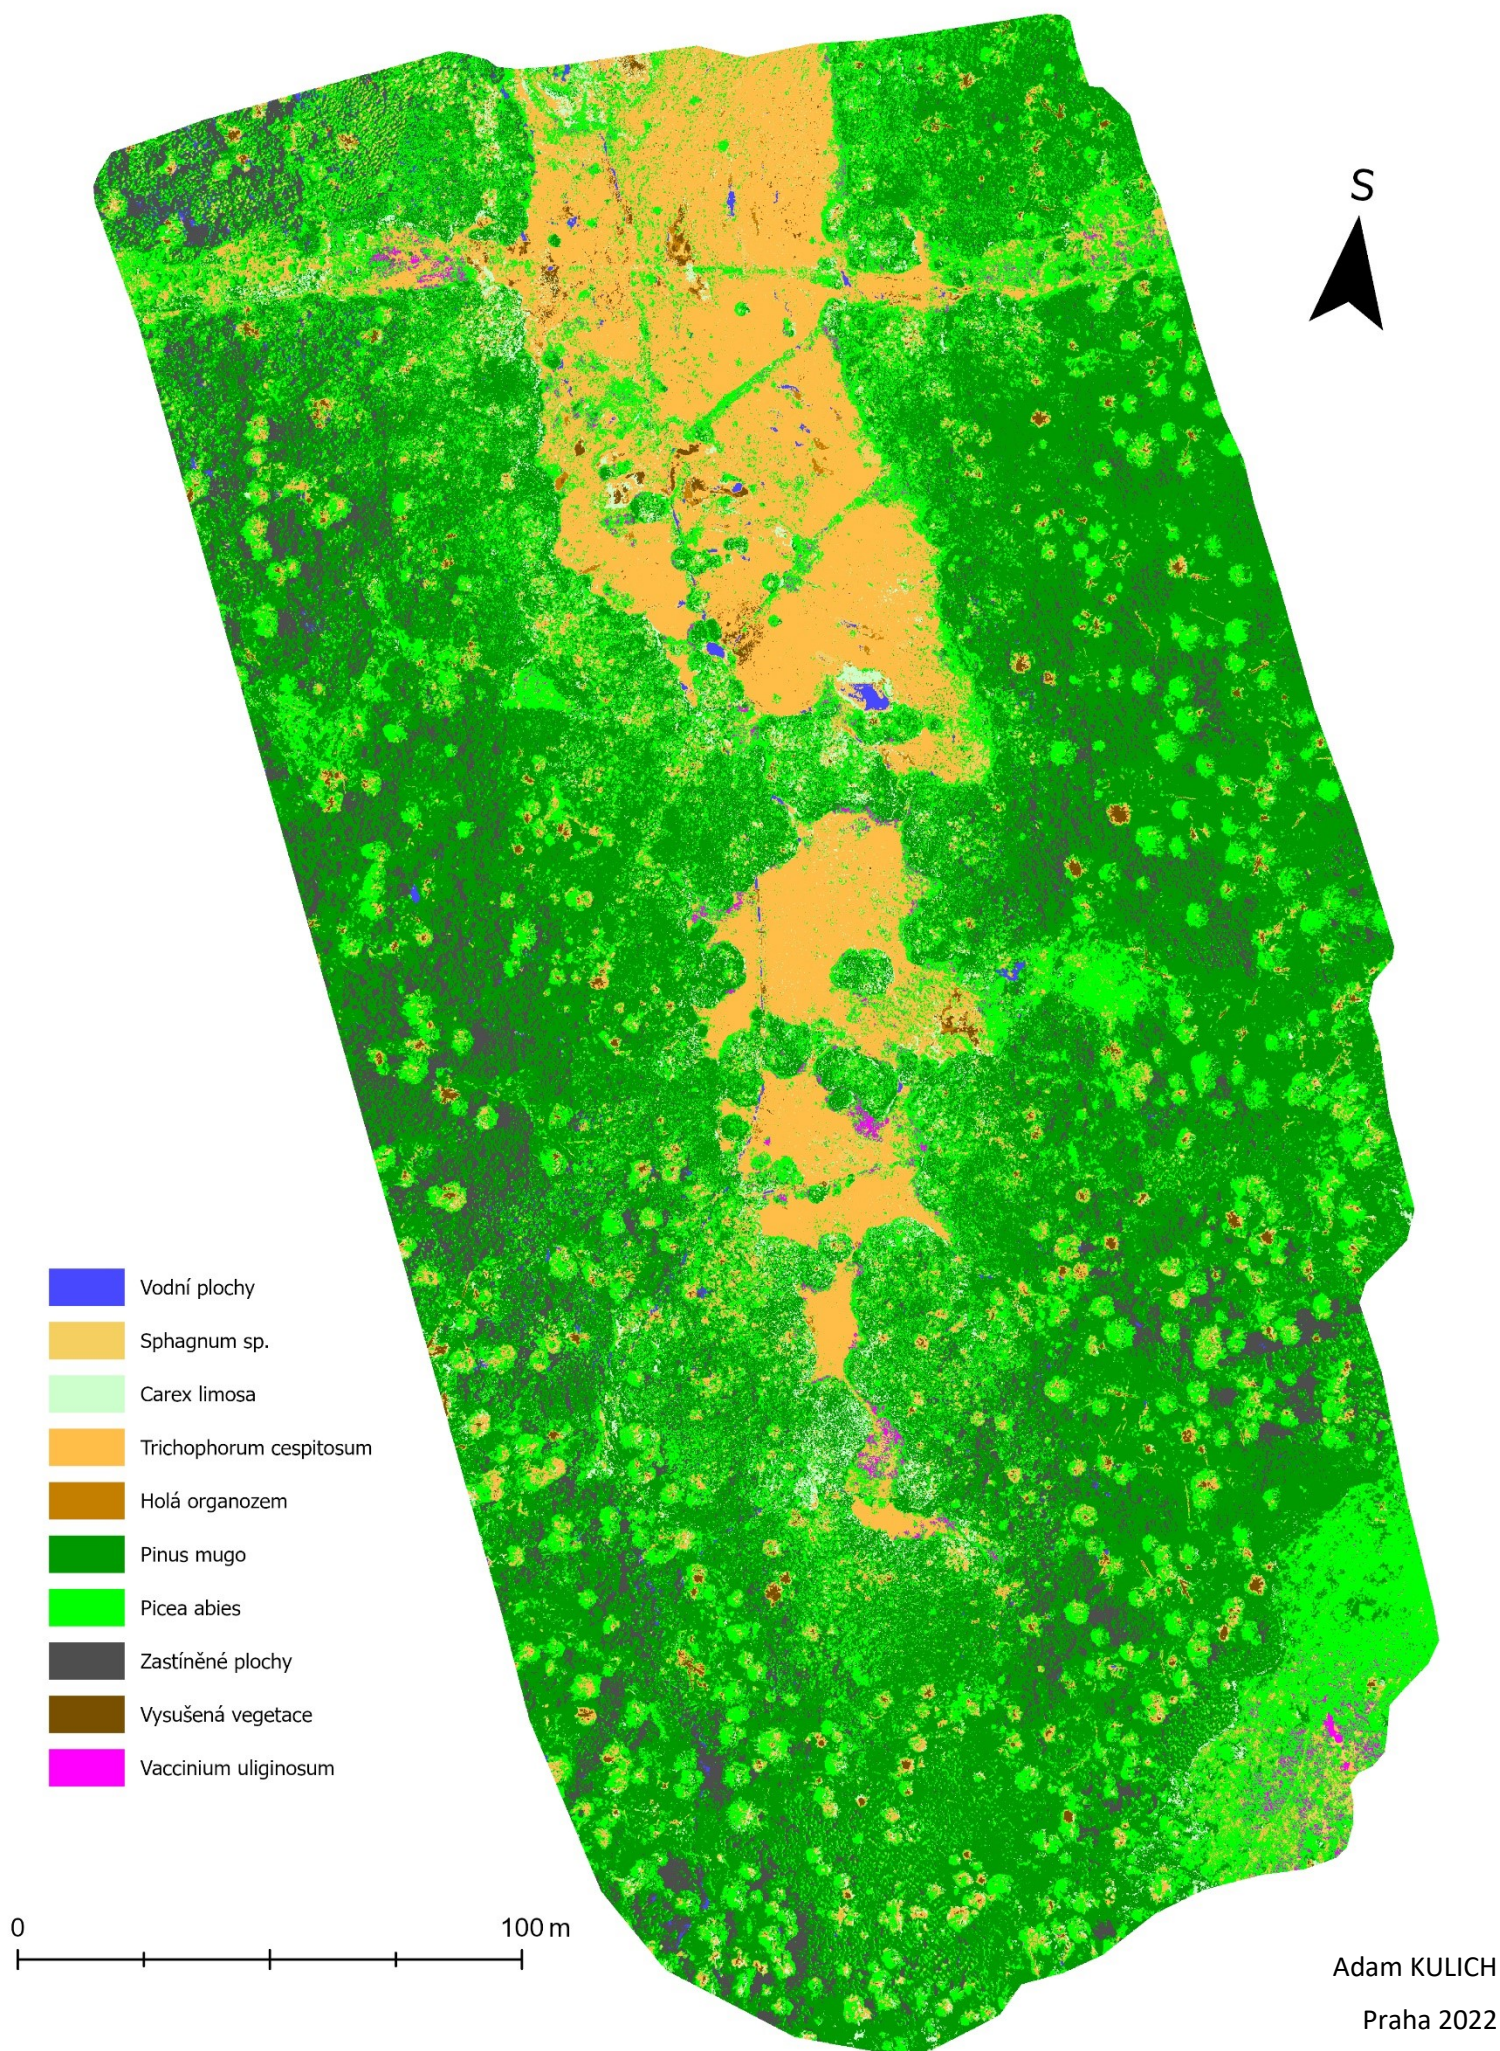
PŘÍLOHA 2: VEGETAČNÍ POKRYV RAŠELINIŠTĚ HRANIČNÍ LOUKA

objektově orientovaná klasifikace




PŘÍLOHA 3: VEGETAČNÍ POKRYV RAŠELINIŠTĚ HRANIČNÍ LOUKA

klasifikace Random forest



PŘÍLOHA 4: VEGETAČNÍ POKRYV RAŠELINIŠTĚ ALFRÉDKA

objektově orientovaná klasifikace




PŘÍLOHA 5: VEGETAČNÍ POKRYV RAŠELINIŠTĚ ALFRÉDKA

klasifikace Random forest

S


0 50 m



- Zastíněné plochy
- Vysušená vegetace
- Calamagrostis villosa
- Picea abies
- Vaccinium myrtillus
- Molinia caerulea
- Pinus mugo
- Carex rostrata
- Vodní plochy
- Sphagnum sp.


PŘÍLOHA 6: VEGETAČNÍ POKRYV RAŠELINIŠTĚ JAKŠÍN

objektově orientovaná klasifikace













PŘÍLOHA 7: VEGETAČNÍ POKRYV RAŠELINIŠTĚ JAKŠÍN

klasifikace Random forest



0 50 m



-  *Picea abies*
-  Zastíněné plochy
-  *Vaccinium myrtillus*
-  Vysušená vegetace
-  *Sphagnum* sp.
-  *Calamagrostis villosa*
-  Vodní plochy
-  *Eriophorum vaginatum*
-  *Molinia caerulea*
-  *Vaccinium uliginosum*

Příloha 8: Tabulky výsledků analýzy překryvů

tabulka: Shody klasifikačních metod v jednotlivých třídách na Hraniční louce

	MA _t RF-SVM	RF-SVM	SVM-RF	MA _t OBIA-RF	OBIA-RF	RF-OBIA
Celková shoda	75,56 %			66,12 %		
Holá organozem	36,26 %	59,51 %	48,12 %	2,63 %	2,87 %	24,40 %
Carex limosa	19,66 %	71,95 %	21,29 %	7,98 %	10,49 %	25,01 %
Pinus mugo	72,39 %	78,75 %	89,96 %	66,24 %	80,17 %	79,22 %
Sphagnum sp.	32,06 %	53,98 %	44,11 %	28,42 %	37,36 %	54,29 %
Picea abies	50,29 %	61,09 %	73,99 %	33,28 %	62,54 %	41,57 %
Zastíněné plochy	73,96 %	94,49 %	77,32 %	40,37 %	53,31 %	62,48 %
Vysušená vegetace	64,34 %	80,93 %	75,87 %	48,52 %	71,72 %	60,03 %
Trichophorum cespitosum	66,95 %	79,80 %	80,58 %	63,74 %	80,83 %	75,10 %
Vaccinium uliginosum	25,11 %	68,30 %	28,42 %	15,40 %	24,1 %	29,90 %
Vodní plochy	52,91 %	84,29 %	58,72 %	9,44 %	10,10 %	59,00 %

tabulka 20: Shody klasifikačních metod v jednotlivých třídách na Alfrédce

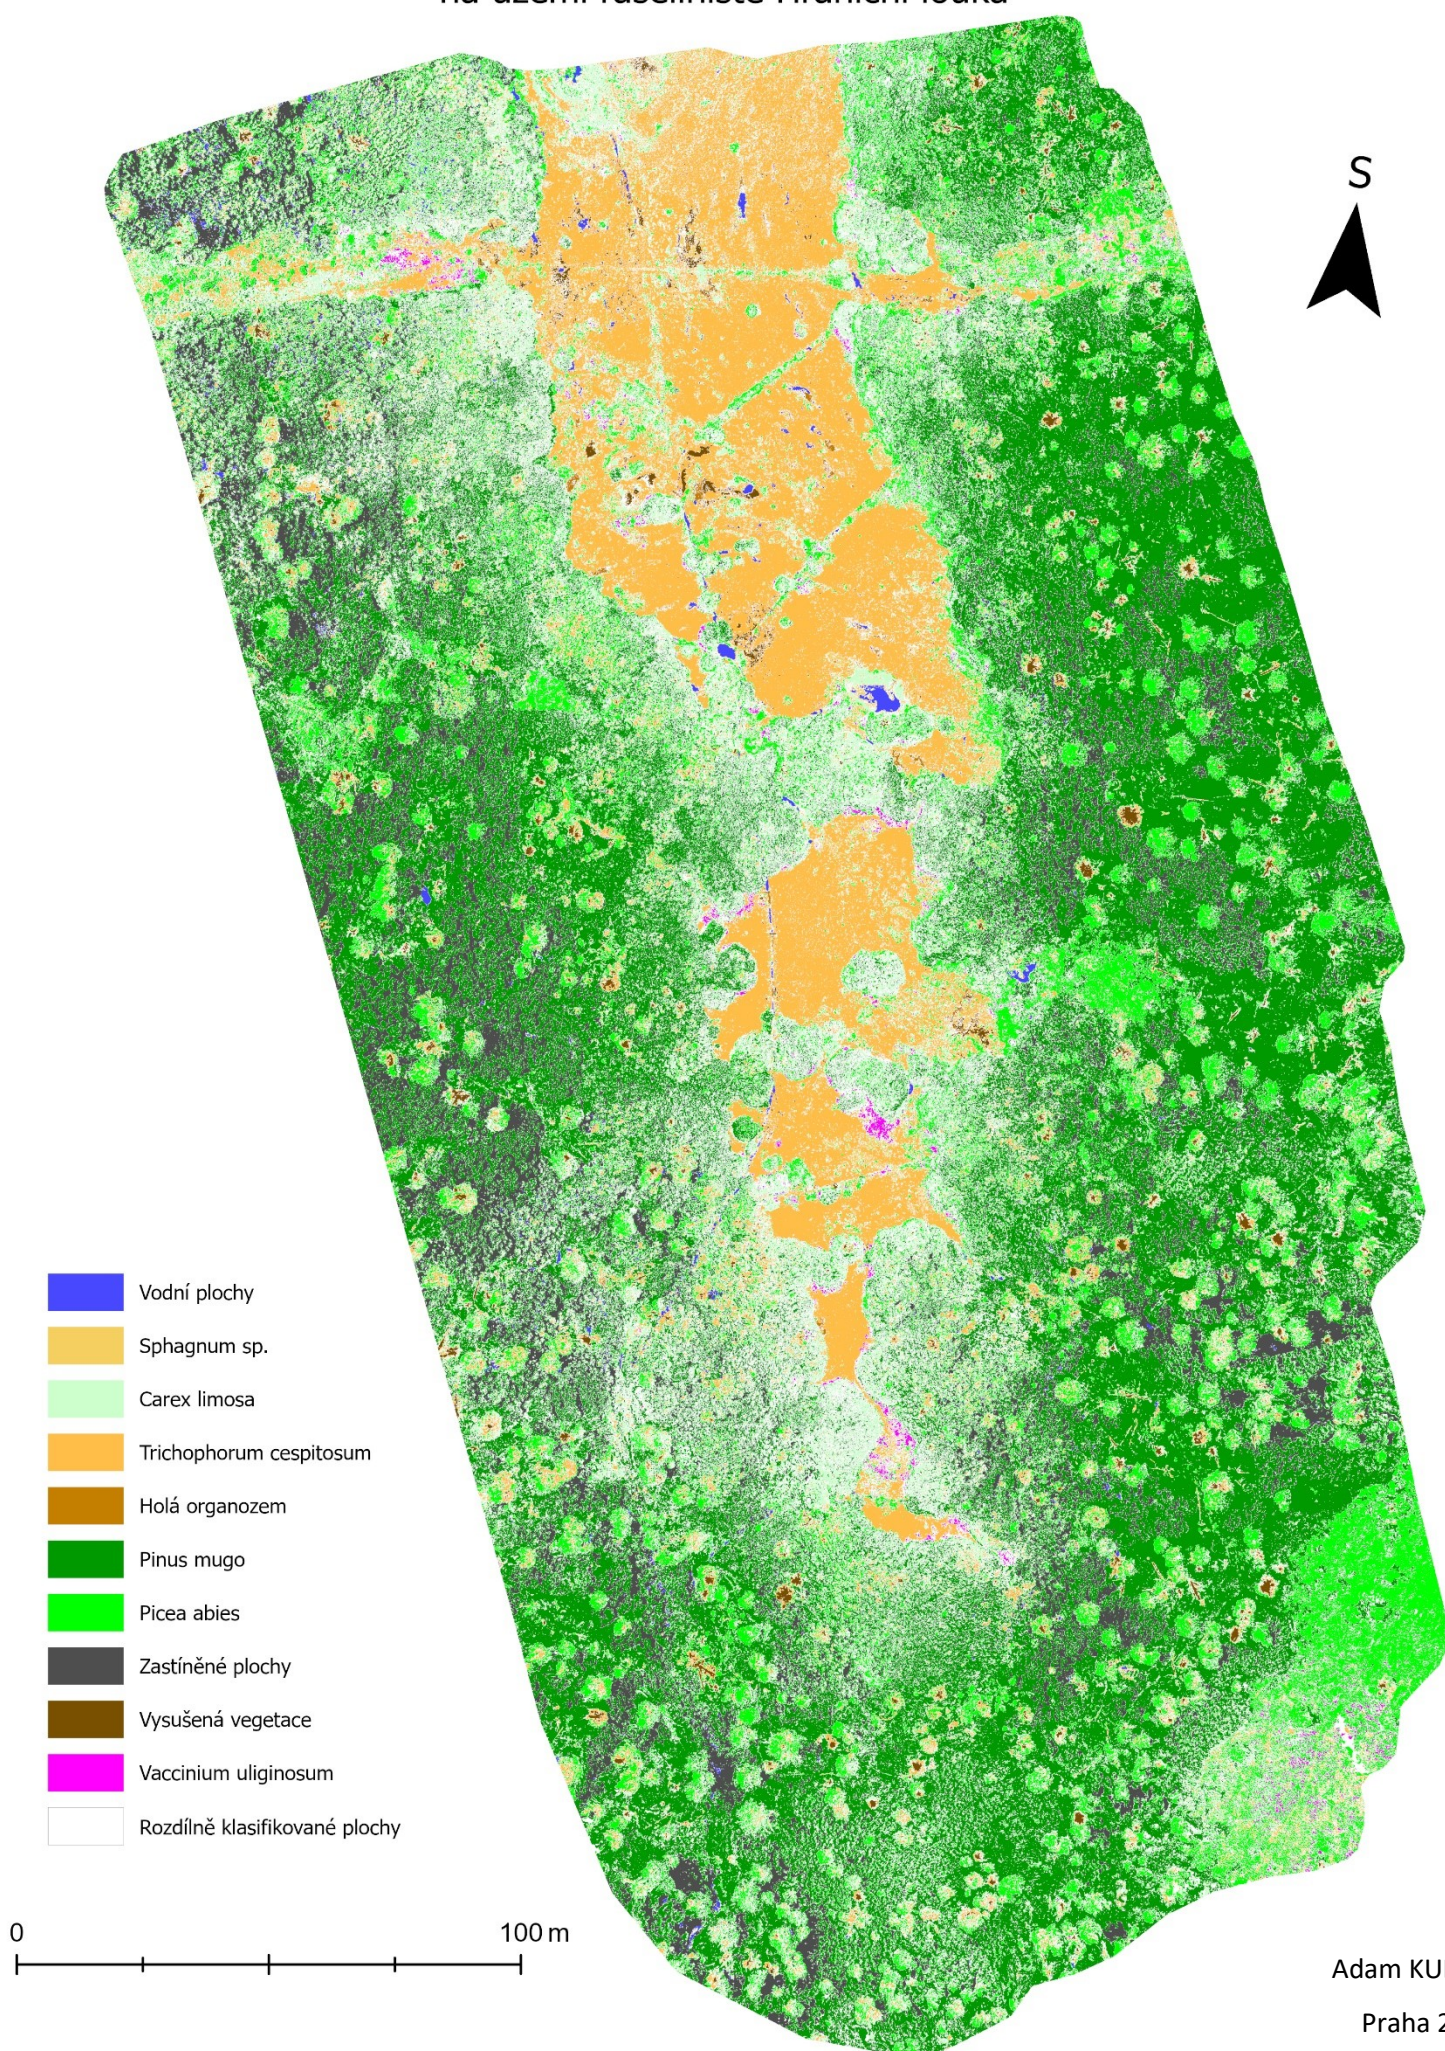
	MA _t RF-SVM	RF-SVM	SVM-RF	MA _t OBIA-RF	OBIA-RF	RF-OBIA
Celková shoda	72,78 %			60,56 %		
Vaccinium myrtillus	48,01 %	70,91 %	59,77 %	50,47 %	65,02 %	69,24 %
Calamagrostis villosa	6,45 %	12,63 %	11,64 %	9,12 %	10,82 %	36,69 %
Pinus mugo	12,66 %	18,38 %	28,92 %	13,13 %	15,42 %	46,88 %
Molinia caerulea	19,07 %	50,17 %	23,51 %	21,23 %	32,48 %	37,97 %
Sphagnum sp.	0,00 %	0,00 %	0,00 %	0,49 %	0,53 %	6,61 %
Carex rostrata	35,86 %	49,58 %	69,27 %	23,37 %	67,63 %	26,32 %
Picea abies	63,76 %	74,94 %	81,06 %	54,06 %	87,26 %	58,70 %
Zastíněné plochy	82,32 %	95,01 %	86,00 %	62,30 %	91,17 %	66,28 %
Vysušená vegetace	70,28 %	94,47 %	73,32 %	67,45 %	73,69 %	88,80 %
Vodní plochy	68,15 %	82,02 %	80,04 %	31,90 %	35,53 %	75,64 %

tabulka 21: Shody klasifikačních metod v jednotlivých třídách na Jakšínu

	MA _t RF-SVM	RF-SVM	SVM-RF	MA _t OBIA-RF	OBJ-RF	RF-OBJ
Celková shoda	56,76 %			37,77 %		
Vaccinium myrtillus	48,01 %	47,25 %	53,14 %	50,47 %	76,62 %	33,15 %
Calamagrostis villosa	6,45 %	15,12 %	41,53 %	9,12 %	34,83 %	1,88 %
Eriophorum vaginatum	12,66 %	48,97 %	47,72 %	13,13 %	5,75 %	9,18 %
Molinia caerulea	19,07 %	24,65 %	35,35 %	21,23 %	13,46 %	31,66 %
Sphagnum sp.	0,00 %	48,15 %	50,47 %	0,49 %	32,17 %	28,09 %
Picea abies	35,86 %	77,02 %	68,38 %	23,37 %	32,65 %	80,75 %
Zastíněné plochy	63,76 %	94,62 %	48,33 %	54,06 %	28,96 %	46,27 %
Vysušené vegetace	82,32 %	84,44 %	83,96 %	62,30 %	34,10 %	85,67 %
Vaccinium uliginosum	70,28 %	24,48 %	41,93 %	67,45 %	5,79 %	35,21 %
Vodní plochy	68,15 %	71,84 %	55,59 %	31,90 %	33,04 %	23,33 %

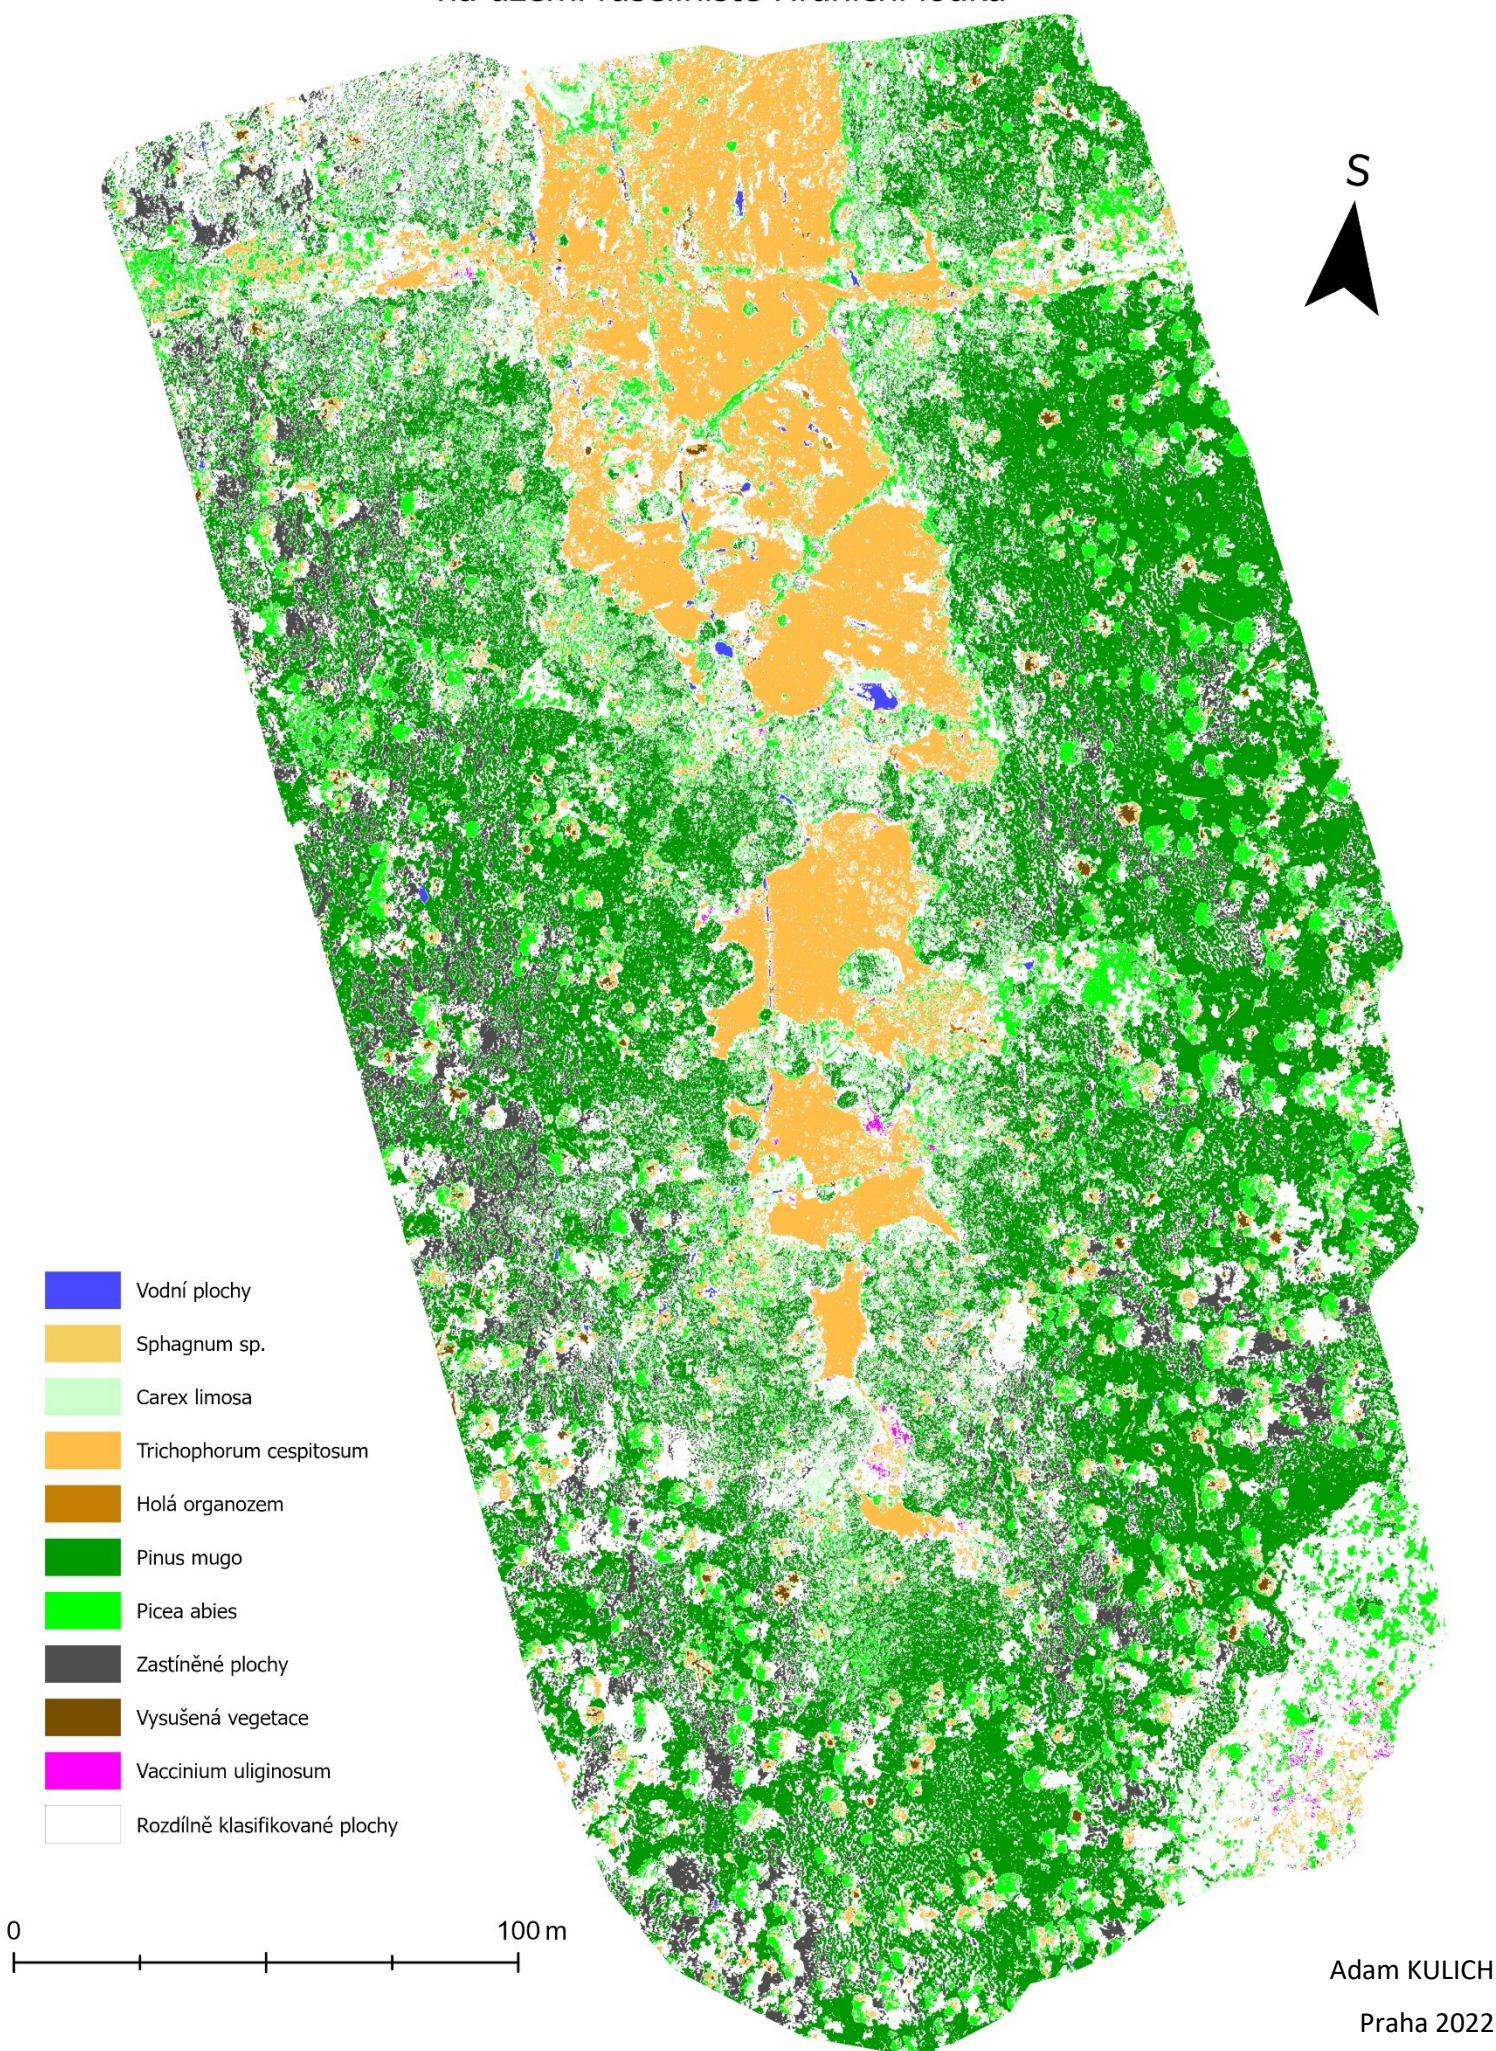
PŘÍLOHA 9: PŘEKRYV KLASIFIKACÍ RANDOM FOREST A SUPPORT VECTOR MACHINE

na území rašeliniště Hraniční louka



PŘÍLOHA 10: PŘEKRYV OBJEKTIVÉ KLASIFIKACE A KLASIFIKACE RANDOM FOREST

na území rašeliniště Hraniční louka




PŘÍLOHA 11: PŘEKRYV KLASIFIKACÍ RANDOM FOREST A SUPPORT VECTOR MACHINE

na území rašeliniště Alfrédka



0 50 m



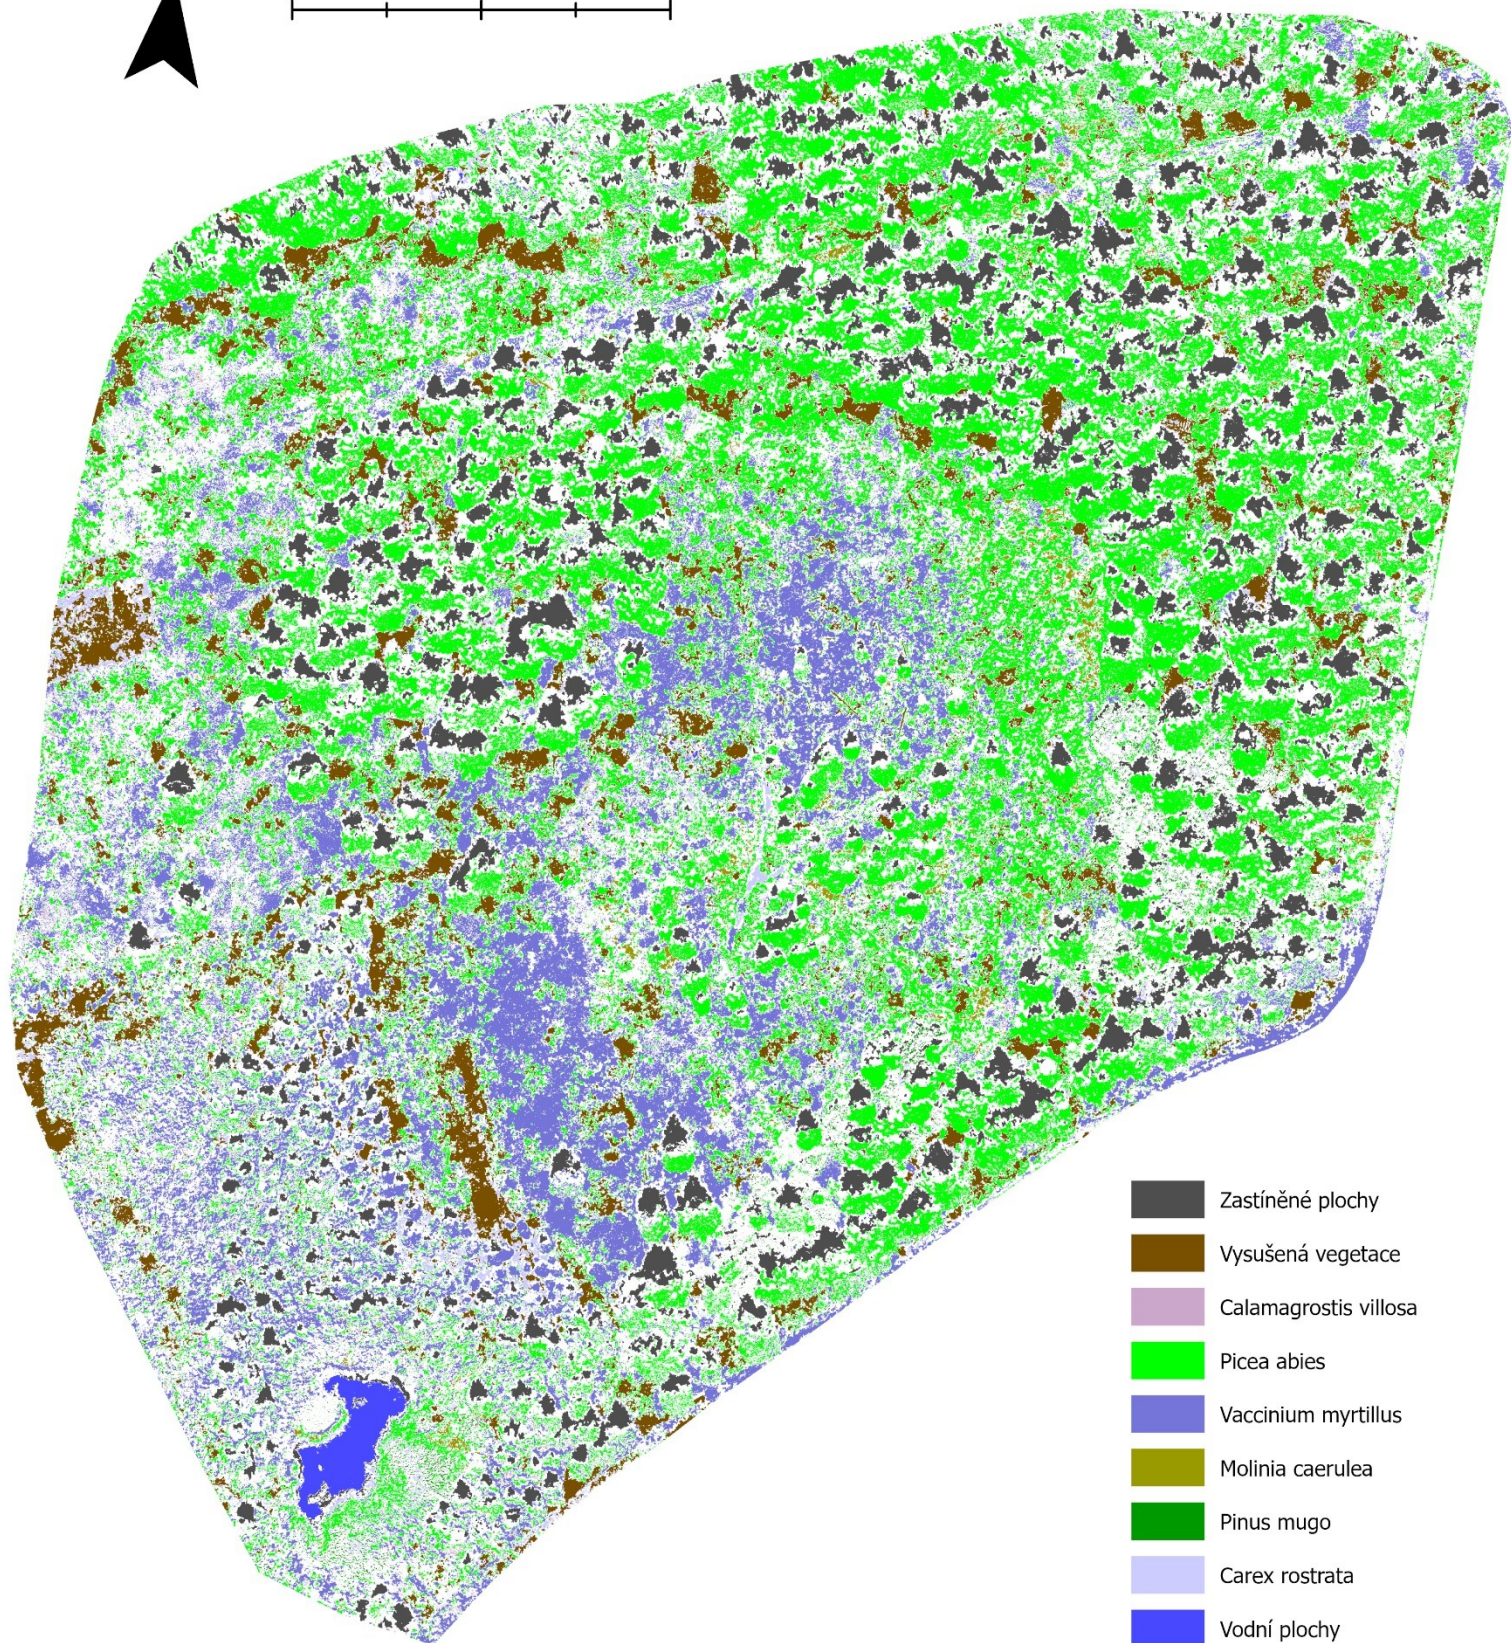
-  Zastíněné plochy
-  Vysušená vegetace
-  Calamagrostis villosa
-  Picea abies
-  Vaccinium myrtillus
-  Molinia caerulea
-  Pinus mugo
-  Carex rostrata
-  Vodní plochy
-  Sphagnum sp.
-  Rozdílně klasifikované plochy

PŘÍLOHA 12: PŘEKRYV OBJEKTIVÉ KLASIFIKACE A KLASIFIKACE RANDOM FOREST

na území rašeliniště Alfrédka



0 50 m















-  Zastíněné plochy
-  Vysušená vegetace
-  Calamagrostis villosa
-  Picea abies
-  Vaccinium myrtillus
-  Molinia caerulea
-  Pinus mugo
-  Carex rostrata
-  Vodní plochy
-  Sphagnum sp.
-  Rozdílně klasifikované plochy


PŘÍLOHA 13: PŘEKRYV KLASIFIKACÍ RANDOM FOREST A SUPPORT VECTOR MACHINE

MACHINE

na území rašeliniště Jakšín




-  *Picea abies*
-  Zastíněné plochy
-  *Vaccinium myrtillus*
-  Vysušená vegetace
-  *Sphagnum* sp.
-  *Calamagrostis villosa*
-  Vodní plochy
-  *Eriophorum vaginatum*
-  *Molinia caerulea*
-  *Vaccinium uliginosum*
-  Rozdílně klasifikované plochy














PŘÍLOHA 14: PŘEKRYV OBJEKTOVÉ KLASIFIKACE A KLASIFIKACE RANDOM FOREST

na území rašeliniště Jakšín



0 50 m



- | | |
|---|-------------------------------|
|  | <i>Picea abies</i> |
|  | Zastíněné plochy |
|  | <i>Vaccinium myrtillus</i> |
|  | Vysušená vegetace |
|  | <i>Sphagnum</i> sp. |
|  | <i>Calamagrostis villosa</i> |
|  | Vodní plochy |
|  | <i>Eriophorum vaginatum</i> |
|  | <i>Molinia caerulea</i> |
|  | <i>Vaccinium uliginosum</i> |
|  | Rozdílně klasifikované plochy |