

Univerzita Karlova
Přírodovědecká fakulta

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Markéta Roubalová

**KLASIFIKACE VYBRANÝCH DRUHŮ VEGETACE V KRKONOŠKÉ TUNDŘE S VYUŽITÍM ČASOVÉ ŘADY
DAT PLANETSCOPE**

**CLASSIFICATION OF SELECTED SPECIES OF VEGETATION IN THE KRKONOŠE MOUNTAINS TUNDRA
BASED ON TIME SERIES OF PLANETSCOPE IMAGERY**

Diplomová práce

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

Jílové u Prahy, 2019

Zadání diplomové práce

pro Markétu Roubalovou
obor Kartografie a geoinformatika

Název tématu: Klasifikace vybraných druhů vegetace v krkonošské tundře s využitím časové řady dat PlanetScope

Zásady pro vypracování:

Diplomová práce se bude zabývat klasifikací vybraných druhů vegetace v krkonošské tundře s využitím časové řady snímků PlanetScope z let 2016 a 2017, která se vyznačují velmi dobrým časovým (1 den) i prostorovým (3 m) rozlišením. Klasifikovány budou tři vybrané druhy jednoděložných trav: smilka tuhá, bezkolenec modrý a třtina chloupkatá, a to na základě jejich sezónních změn. Cílem práce je zjistit, do jaké míry lze rozlišit v datech PlanetScope tyto druhy vegetace a zda multitemporální přístup přispěje ke zlepšení přesnosti klasifikace. Cílem je také zjistit, v jakém období jsou od sebe vybrané vegetační druhy nejlépe odlišitelné a který z dostupných termínů je pro klasifikaci nejvhodnější. Využity budou vybrané metody pixelové a objektové klasifikace. Jednou z nich bude klasifikátor Random Forest, který dosud nebyl pro tyto účely využíván a který může být v práci za účelem zlepšení přesnosti klasifikace upraven v prostředí software R.

Rozsah grafických prací: Dle potřeby

Rozsah průvodní zprávy: Cca 60 stran

Seznam odborné literatury:

Cao, G., Zhou, L., & Li, Y. (2016). A new change-detection method in high-resolution remote sensing images based on a conditional random field model. *International Journal of Remote Sensing*, 37(5), 1173-1189.

Chen, G., Hay, G. J., Carvalho, L. M., & Wulder, M. A. (2012): Object-based change detection. *International Journal of Remote Sensing*, 33(14), 4434-4457.

Kupková, L. et al. (2017): Classification of Tundra Vegetation in the Krkonoše Mts. National Park Using APEX, AISA Dual and Sentinel-2A Data. *European Journal of Remote Sensing* 50, 29-46. Dostupné z: <http://dx.doi.org/10.1080/22797254.2017.1274573>

Peng, D., & Zhang, Y. (2017): Object-based change detection from satellite imagery by segmentation optimization and multi-features fusion. *International Journal of Remote Sensing*, 38(13), 3886-3905.

Rodriguez-Galiano, V.F., Chica-Olmo, M., Abarca-Hernandez, F., Atkinson, P.M. and Jeganathan, C., (2012): Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. *Remote Sensing of Environment*, 121, 93-107.

Suchá R., Jakešová L., Kupková L., Červená L. (2016): Classification of vegetation above the tree line in the Krkonoše Mts. National Park using remote sensing multispectral data. *AUC GEOGRAPHICA*, 51(1): 113–129. DOI: <http://dx.doi.org/10.14712/23361980.2016.10>.

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

Datum zadání diplomové práce: 20.12.2017

Termín odevzdání diplomové práce: červenec 2019

.....
Vedoucí diplomové práce

.....
Garant studijního oboru

V Praze dne: 30.11.2018

Prohlášení

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

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

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

V Jílovém u Prahy dne 19.7.2019

.....
Markéta Roubalová

Poděkování

Ráda bych tímto poděkovala vedoucí mé práce RNDr. Lucii Kupkové, Ph.D. za věnovaný čas a cenné rady, které mi v průběhu tvorby práce poskytovala a Mgr. Lucii Červené, Ph.D. za poskytnuté materiály. Děkuji také společnosti Planet za poskytnutí družicových dat PlanetScope.

Abstrakt

Cílem práce bylo zjistit, do jaké míry lze s využitím dat PlanetScope rozlišit tři druhy travin - bezkoleneček modrý (*Molinia caerulea*), třtina chloupkatá (*Calamagrostis villosa*) a smilka tuhá (*Nardus stricta*) v krkonošské tundře a zda multitemporální přístup může přispět ke zvýšení přesnosti klasifikace těchto druhů. Využito bylo dat PlanetScope s prostorovým rozlišením 3 m. Řízená pixelová klasifikace Maximum Likelihood, Support Vector Machine, Random Forest a objektová klasifikace SVM proběhly v programu ENVI 5.3 na základě terénních dat zaměřených GPS přístrojem v letech 2014 až 2018. Jednotlivé přesnosti klasifikace byly porovnány s výstupy řízené klasifikace v Kupková et al. (2017) a Marcinkowska-Ochytra et al. (2018a). Nejlepší výsledek klasifikace byl dosažen pro multitemporální kompozit metodou Random Forest. Celková přesnost klasifikace byla 80,67 %, což je lepší výsledek, než v případě klasifikace snímku z jednoho termínu (celková přesnost 76,06 %). Data PlanetScope byla porovnána s daty RapidEye a Apex. V rámci dat RapidEye dosáhl nejvyšší celkové přesnosti multitemporální kompozit klasifikovaný metodou Random Forest (74,75 %), v případě dat Apex (termín 10.9.2012) bylo dosaženo nejlepšího výsledku také metodou Random Forest (75,91 %).

Klíčová slova: multitemporální klasifikace, vegetace, spektrální příznaky, PlanetScope, tundra, Krkonošský národní park, Random Forest, *Molinia caerulea*, *Calamagrostis villosa*, *Nardus stricta*

Abstract

The aim of this thesis was to test the suitability of PlanetScope imagery to differentiate and evaluate the possibility of multi-temporal approach to improve classification accuracy of selected vegetation species (*Molinia caerulea*, *Calamagrostis villosa*, *Nardus stricta*) in eastern tundra in the Krkonoše Mts. National Park. PlanetScope imagery - 4 spectral bands with spatial resolution 3 m - was used. Per-pixel classifications Maximum Likelihood, Support Vector Machine and Random Forest and object-based classification SVM were executed in software ENVI 5.3. based on GPS field data collected from 2014 till 2018. The best classification results were compared to classification results in Kupková et al. 2017 and Marcinkowska-Ochytra et al. (2018a). The overall accuracy of the best classification result (multitemporal composite using Random Forest classifier) was 80,67 %. It is better result than in the case of single image classification (overall accuracy was 76,06 %). PlanetScope data were compared to RapidEye and Apex data. The overall accuracy of the RapidEye best classification result (multitemporal composite using Random Forest classifier) was 74,75 %, the best overall accuracy of monotemporal classification of Apex data reached 75,91 %.

Key words: multi-temporal classification, vegetation, spectral features, PlanetScope, tundra, The Krkonoše Mts. National Park, Random Forest, *Molinia caerulea*, *Calamagrostis villosa*, *Nardus stricta*

Obsah

Seznam obrázků a tabulek.....	10
Seznam použitých zkratk 13	13
1 Úvod a cíle práce	14
2 Literární rešerše a úvod do problematiky	16
2.1 Klasifikace	16
2.2 Klasifikátory	17
2.2.1 Random Forest	17
2.2.1.1 Textura.....	20
2.2.2 Klasifikátor maximální věrohodnosti.....	21
2.2.3 Support Vector Machine	22
2.3 Multitemporální přístup ke klasifikaci.....	22
2.4 Klasifikace v tundře	22
2.5 Klasifikace v krkonošské tundře	23
2.6 Klasifikace dat PlanetScope	25
2.7 Atmosférické korekce.....	26
2.7.1 Atmosférické korekce dat PlanetScope.....	26
3 Zájmové území	29
3.1 Hodnocené kategorie vegetačního pokryvu	31
3.2 Průběh počasí ve sledovaných letech.....	33
4 Data a metodika	35
4.1 Data	35
4.1.1 Data systému družic PlanetScope	35
4.1.2 Data družic RapidEye.....	36
4.1.3 Hyperspektrální dat Apex.....	37
4.1.4 Terénní data	38
4.1.5 Ostatní datové zdroje	38
4.2 Předzpracování dat.....	38
4.2.1 Atmosférické korekce.....	38
4.2.2 Klasifikační maska.....	38
4.3 Analýza dat	39
4.3.1 Analýza spektrálních příznaků sledovaných kategorií.....	39
4.3.2 Klasifikace	40
5 Výsledky.....	47
5.1 Atmosférické korekce.....	47
5.2 Analýza spektrálních příznaků sledovaných kategorií.....	48

5.3	Klasifikace	51
5.3.1	Porovnání atmosféricky korigovaných dat PlanetScope	51
5.3.1.1	Maximum Likelihood	51
5.3.1.2	Support Vector Machine	53
5.3.1.3	RandomForest	54
5.3.1.4	Objektová klasifikace.....	56
6	Diskuze.....	58
7	Závěr	62
	Použitá literatura.....	64
	Seznam příloh.....	68

Seznam obrázků a tabulek

Obr. 1: Proces výpočtu GLCM (Mathworks, 2019)	21
Obr. 2: Porovnání hodnot EVI dat PlanetScope před a po atmosférické korekci (zdroj: Planet Surface Reflectance Product, 2018)	27
Obr. 3: Porovnání hodnot EVI dat PlanetScope a Landsat po atmosférické korekci (zdroj: Planet Surface Reflectance Product, 2018)	27
Obr. 4: Porovnání hodnot odrazivosti da PlanetScope a Landsat po atmosférické korekci v pásmech Blue, Green, Red a NIR, (zdroj: Planet Surface Reflectance Product, 2018)	28
Obr. 5: Mapa zájmového území (vlastní zpracování)	30
Obr. 6: Změny bezkolence modrého v průběhu vegetační sezóny v termínech 15.6.2017, 28.6.2017, 4.8.2016, 29.8.2014, 17.8.2015 (pořadí zleva), foto: Lucie Červená.....	31
Obr. 7: Změny smilky tuhé v průběhu vegetační sezóny (červen-srpen) v termínech 15.6.2017, 28.6.2017, 6.8.2016, 16.8.2015, 28.8.2014 (pořadí zleva), foto: Lucie Červená.....	32
Obr. 8: Změny třtiny chloupkaté v průběhu vegetační sezóny (červen-srpen) v termínech 15.6.2017, 27.6.2014, 6.8.2016, 17.8.2015, 28.8.2014 (pořadí zleva), foto: Lucie Červená.....	32
Obr. 9: Průměrná teplota vzduchu na Sněžce od května do září v letech 2016, 2017 a 2018 (zpracováno dle Meteomanz, 2019)	33
Obr. 10: Měsíční úhrn srážek na Sněžce od května do září v letech 2016, 2017 a 2018 (zpracováno dle Meteomanz, 2019)	33
Obr. 11: Počet dní s výskytem sněhových srážek na Sněžce v letech 2016, 2017 a 2018 (zpracováno dle Meteomanz, 2019)	34
Obr. 12: Družice PlanetScope (Gisgeography, 2019).....	35
Obr. 13: Družice RapidEye (Geoimage, 2019)	37
Obr. 14: Klasifikační maska.....	39
Obr. 15: Rozmístění trénovacích a validačních ploch pro klasifikaci.....	40
Obr. 16: Pracovní postup (pozn. MK – multitemporální kompozit, S – soubor)	43
Obr. 17: Průměrné odrazivosti odlišných povrchů termínu 7.8.2018 z dat korigovaných PlanetScope SR, korigovaných modelem QUAC a atmosféricky nekorigovaných	48
Obr. 18: Průměrná odrazivost trénovacích ploch v jednotlivých termínech v NIR	50
Obr. 19: Průměrné hodnoty NDVI ve sledovaných termínech.....	51
Obr. 20: Průměrná odrazivost trénovacích ploch v NIR a celková přesnost klasifikace MLC dat PlanetScope v jednotlivých termínech	59
Tab. 1: Spektrální pásma PlanetScope (zpracováno dle Planet, 2018)	35
Tab. 2: Bezoblačné termíny dat PlanetScope využité pro klasifikaci a spektrální analýzu.....	36
Tab. 3: Spektrální pásma RapidEye (zpracováno dle Planet, 2018)	36
Tab. 4: Bezoblačné termíny dat RapidEye využité pro klasifikaci.....	37

Tab. 5: Plochy pro analýzu spektrálních příznaků	40
Tab. 6: Trénovací a validační plochy pro klasifikaci (pro prostorové rozlišení dat PlanetScope).....	41
Tab. 7: Multitemporální kompozity dat PlanetScope s odlišnou metodou provedení atmosférické korekce	41
Tab. 8: Multitemporální kompozity dat PlanetScope a RapidEye	42
Tab. 9: Testované kombinace spektrálních pásem dat APEX.....	42
Tab. 10: Proměnné vstupující do klasifikace RF	45
Tab. 11: Počty proměnných vstupujících do klasifikace RF pro různé typy dat	45
Tab. 12: Průměrné odrazivosti odlišných povrchů napříč termíny dat PlanetScope	47
Tab. 13: Průměrné odrazivosti odlišných povrchů napříč termíny dat PlanetScope s atmosférickou korekcí QUAC.....	48
Tab. 14: Porovnání klasifikačních přesností pro data s odlišnou metodou provedení atmosférické korekce	51
Tab. 15: Celkové přesnosti klasifikace dat PlanetScope klasifikátorem MLC pro jednotlivé termíny a multitemporální kompozit	52
Tab. 16: Zpracovatelská a uživatelská přesnost klasifikace dat PlanetScope klasifikátorem MLC pro jednotlivé termíny a multitemporální kompozit	52
Tab. 17: Porovnání přesností klasifikace MLC pro jednotlivé termíny a multitemporální kompozit dat PlanetScope, RapidEye a APEX.....	53
Tab. 18: Rozlohy sledovaných travin v klasifikovaných termínech let 2016, 2017 a 2018 vypočítané na základě snímků klasifikovaných MLC.....	53
Tab. 19: Porovnání přesností klasifikace SVM pro jednotlivé termíny a multitemporální kompozit dat PlanetScope, RapidEye a APEX.....	54
Tab. 20: Zpracovatelská a uživatelská přesnost klasifikace dat PlanetScope metodou RF pro nejlépe hodnocený termín a multitemporální kompozit.....	54
Tab. 21: Chybová matice klasifikace Random Forest pro Kompozit 2.....	54
Tab. 22: Celková přesnost klasifikace RF klasifikátorem RF pro nejlépe hodnocený termín a multitemporální kompozit	55
Tab. 23: Klasifikační přesnosti pro jednotlivé kategorie proměnných pro termín 7.8.2018.....	55
Tab. 24: Důležitost proměnných pro nejlépe klasifikovaný termín 7.8.2018 (prvních 10)	55
Tab. 25: Porovnání celkových přesnosti klasifikace pro nejlépe klasifikované termíny.....	56
Tab. 26: Porovnání zpracovatelské a uživatelské přesnosti klasifikace dat PlanetScope klasifikátory RF a MLC pro multitemporální kompozit dat PlanetScope	56
Tab. 27: Porovnání pixelové a objektové klasifikace (nejlépe klasifikované soubory – Kompozit 2 a termín 7.8.2018 SR).....	57
Tab. 28: Porovnání výsledků klasifikace RF multitemporálního kompozitu a SVM klasifikace dat AISA Dual (zpracováno dle Kupková et al., 2017)	61

Tab. 29: Porovnání výsledků RF klasifikace multitemporálního souboru dat a SVM klasifikace dat APEX (zpracováno dle Marcinkowska-Ochytra et al., 2018a)	61
---	----

Seznam použitých zkratk

APEX	Advanced Photovoltaic and Electronics Experiments
DEM	Digital elevation model
DPZ	Dálkový průzkum Země
EnMAP	Environmental Mapping and Analysis Program
ESA	European Space Agency
GLCM	Gray-Level Co-Occurrence Matrix
GPS	Global Positioning System
ISODATA	Iterative Self-Organizing Data Analysis Technique
KRNAP	Krkonošský národní park
LIDAR	Light Detection And Ranging
MDI	Moment Distance Index
MLC	Maximum Likelihood Classification
MNF	Minimum Noise Fraction
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NIR	Near Infrared Band
NN	Neural Network
PCA	Principal Component Analysis
QUAC	Quick Atmospheric Correction
RF	Random Forest
SR	Surface reflectance

1 Úvod a cíle práce

Práce se zabývá územím, které je součástí Krkonošského národního parku, konkrétně východní části krkonošské reliktní tundry. Nachází se nad horní hranicí lesa a je, mimo jiné, charakteristické vysokou druhovou rozmanitostí vegetace. Jedná se o jedinečný ekosystém, který je velmi citlivý na různé faktory prostředí a podléhá přísné ochraně.

V rámci požadavku Správy Krkonošského národního parku (KRNAP) na monitoring vegetačních změn jsou hledány metody, které by odstranily nedostatky terénního mapování (časová náročnost, subjektivní chyba). Jednou z testovaných metod, která má potenciál zmíněné nevýhody odstranit, je dálkový průzkum Země (DPZ).

Hlavním cílem této práce je zjistit, do jaké míry lze v rámci zájmového území s využitím dat PlanetScope rozlišit tři vybrané druhy jednoděložných trav – bezkolenec modrý (*Molinia caerulea*), třtina chloupkatá (*Calamagrostis villosa*) a smilka tuhá (*Nardus stricta*). Tyto vegetační kategorie byly vybrány z důvodu ověření předpokladu Správy KRNAP o rozrůstání bezkolence modrého a třtiny chroupkaté na úkor původní smilky tuhé. Práce se dále zabývá otázkou, v jakém období jsou od sebe vybrané vegetační druhy, které v průběhu vegetační sezóny mění svůj vzhled, barvu a pokrývnost, nejlépe odlišitelné a který z dostupných termínů je pro klasifikaci nejvhodnější. Za cíl si také klade zjistit, zda multitemporální přístup a klasifikátor Random Forest přispěje ke zlepšení přesnosti klasifikace a zda je vhodnější využití pixelové či objektové klasifikace.

Základním datovým zdrojem jsou multispektrální data PlanetScope, která mají prostorové rozlišení 3 m a časové rozlišení 1 den. Pro porovnání výsledků je využito také dat RapidEye a Apex, která disponují odlišným prostorovým, spektrálním i časovým rozlišením.

Práce se nejprve zabývá analýzou spektrálních příznaků sledovaných kategorií, kde porovnává, jak se od sebe sledované druhy v průběhu vegetační sezóny odlišují. Následně jsou na základě legendy, která byla stanovena botanikem Krkonošského národního parku, pixelovými klasifikátory MLC (Maximum Likelihood), SVM (Support Vector Machine) a RF (Random Forest) analyzovány snímky z vybraných termínů, stejně tak jako multitemporální kompozity. Objektového přístupu je využito pouze pro ta data, která dosáhla pixelovým přístupem nejlepších výsledků. Přesnosti všech klasifikací jsou hodnoceny s využitím chybové matice a vzájemně porovnány. Referenční polygony pro klasifikaci byly nasbírány v terénu pomocí GPS přístroje v letech 2014-2018.

Předpokladem práce je, že vysoké časové a prostorové rozlišení snímků PlanetScope by mohlo přispět ke zvýšení přesnosti klasifikace vybraných vegetačních kategorií. Využití časové řady dat by

mělo přinést přesnější výsledky i vzhledem k sezónním odlišnostem vegetace, které by měly být zřetelné v jejím spektrálním projevu.

2 Literární rešerše a úvod do problematiky

2.1 Klasifikace

Klasifikace je proces, při kterém dochází k rozřazování jednotlivých obrazových prvků, v tomto případě pixelů, do informačních tříd. V jejím průběhu jsou původní naměřené radiometrické hodnoty, které vyjadřují spektrální vlastnosti pixelů, nahrazeny hodnotami, které umožňují určit příslušnost k dané kategorii (Dobrovolný, 1998). Základem klasifikačního procesu je využití klasifikátoru neboli rozhodovacího pravidla, či algoritmu, na jehož základě jsou prvky zařazovány do ustanovených tříd (Kolář, Halounová, Pavelka, 1997). Klasifikace lze dělit dle mnoha kritérií, mezi základní typy se řadí pixelová a objektová, případně řízená a neřízená. Pro provedení řízené klasifikace jsou vyžadovány trénovací plochy, které představují klasifikovanou třídu. Podle Campbell (2011) se jedná se o jeden z nejdůležitějších faktorů ovlivňujících úspěšnost klasifikace. Tento typ klasifikace je sice zpracovatelsky náročnější, ale obvykle přináší lepší výsledky než neřízený přístup.

Pixelová klasifikace

Tradiční metody klasifikace, nazývané jako pixelové, využívají pixely jako základní jednotku analýzy. Rozhodovací pravidla jsou v tomto případě vztažena pouze k pixelu a jsou vyhodnocovány zvlášť, bez ohledu na vlastnosti pixelů okolních. Pixelový přístup nezohledňuje kontextuální informaci v obraze, což může vést ke snížení přesnosti klasifikace (Weigh, Roggan, 2010).

Objektová klasifikace

Díky rozvoji informačních technologií, který umožňuje využití řady segmentačních algoritmů, je stále jednodušší a častější využití objektového přístupu. Ten do klasifikačního procesu umožňuje zahrnout kontextuální informaci a vlastnosti jednotlivých objektů. Výsledkem objektové analýzy je model, který velmi věrně odráží vztahy v reálném světě.

Základním prvkem objektové klasifikace je objekt. Chen et al. (2012) jej definuje jako soubor spektrálně si podobných sousedních pixelů. Kromě spektrální informace nesou objekty také prostorovou a geometrickou informaci. Jak uvádí Blatschke (2010), právě tyto vlastnosti nám umožňují ze snímku získat důležité geoprostorové informace, jejichž využití v klasifikačním procesu vede ke zlepšení jeho přesnosti. Zásadním procesem, který ovlivňuje výsledek objektové klasifikace, je segmentace. V jejím průběhu je snímek rozčleněn do segmentů, ze kterých jsou na základě spektrálních, prostorových a dalších vlastností generovány objekty. Protože se reálné objekty, které se nacházejí na klasifikovaném snímku, vyznačují různými velikostmi a tvary, je v případě pixelového přístupu složité určit prostorové rozlišení, které by bylo schopné vhodně zachytit všechny charakteristiky sledovaných objektů. Objektová klasifikace umožňuje v rámci jednoho snímku

definovat různé krajinné prvky pomocí objektů rozdílných velikostí, které se ale skládají z pixelů stejného prostorového rozlišení. K vhodnému vymezení těchto objektů je využito například spektrálních, prostorových, či texturálních parametrů (Chen et al., 2012). Podle Blatschke (2010) vhodnost užití objektového přístupu roste se zvyšujícím se prostorovým rozlišením. Chen et al. (2012) zmiňuje, že studium této oblasti DPZ se velmi rychle vyvíjí a v současné době je známo mnoho metod, které využívají odlišných přístupů a které mohou, v porovnání s tradičními metodami, přinést lepší výsledky. Cao, Li, Zhou (2016a) také uvádí, že většina studií testovala využití metod objektové klasifikace na datech středního a nízkého prostorového rozlišení, velmi málo výzkumů ale využilo dat vysokého a velmi vysokého prostorového rozlišení.

2.2 Klasifikátory

2.2.1 Random Forest

Random Forest (RF) je metoda řízené klasifikace (Salas, Boykin, Valdez, 2016). Podle Gao et al. (2015a) představuje tento algoritmus strojového učení soubor individuálních stromových klasifikátorů, kde každý strom přispívá jedním hlasem k volbě nejfrekventovanější třídy. Využívá k tomu náhodný výběr vstupních proměnných v dělení každého uzlu. Random Forest využívá v klasifikačním procesu velké množství rozhodovacích stromů. Trénovací data jsou vybírána ze souboru všech těchto dat pro každý rozhodovací strom zvlášť a zcela náhodně (Yoon, Choi 2018). V procesu RF klasifikace jsou vyžadovány pouze 2 základní parametry: počet stromů a počet vstupních proměnných (Gao et al., 2015b). Podle Salas, Boykin, Valdez (2016) jsou hlavními výhodami RF robustnost vůči datovému šumu a schopnost zpracování velkého množství vstupních proměnných a následné vyhodnocení jejich důležitosti v klasifikačním procesu. Rodriguez-Galiano et al. (2012b) mezi pozitiva řadí ještě vysokou klasifikační přesnost a fakt, že se jedná o neparametrický klasifikátor. Jedná se o metodu, která je v oblasti dálkového průzkumu Země relativně neznámá a v porovnání s ostatními dostupnými metodami ještě nebyla dostatečně testována. Avšak díky výše zmíněným pozitivům se v tomto oboru stává stále více populární (Rodriguez-Galiano et al., 2012b). Jak uvádí Pal (2005), Random Forest klasifikátor umožňuje výrazné zlepšení přesnosti klasifikace vegetačního pokryvu.

Vhodnost využití Random Forest byla testována i v několika výzkumech zabývajících se klasifikací vegetace. Ve většině z nich je největší důraz kladen na výběr vhodných vstupních proměnných.

Salas, Boykin, Valdez (2016) využil metodu RF ke klasifikaci vegetace v oblasti východního Pamíru. Využito bylo snímků Landsat a klasifikováno bylo 5 vegetačních kategorií (řídká vegetace, středně hustá vegetace, hustá vegetace, holá půda a vodní plochy). Testována byla důležitost

spektrálních, texturálních a topografických proměnných. Právě texturální proměnné jsou v případě objektové klasifikace hojně využívány a bylo potvrzeno, že pomáhají zpřesňovat klasifikační výsledky. Textura měří variabilitu na základě rozložení odstínů šedi sousedních pixelů v obraze a dává tak uživateli informaci o struktuře povrchu, souměrnosti atd. V případě klasifikace vysokohorské vegetace se jako nejvýznamnější pro přesnost klasifikačního procesu ukázaly spektrální proměnné (NDVI, MDI), důležitost ale ukázalo například také využití DEM. Naopak jako méně důležité bylo v tomto případě vyhodnoceno samostatné užití textury, málo významné potom topografické proměnné (sklon a orientace). Nejvyšší klasifikační přesnosti (92 %) bylo dosaženo kombinací MDI (moment distance index) a texturálních proměnných.

Klasifikátoru Random Forest využil také Silveira et al. (2018) ke klasifikaci savan a semiaridních lesů v Brazílii. Na datech středního rozlišení (Sentinel 2, Landsat 8) proběhla objektová klasifikace. Z blízkého infračerveného pásma a NDVI byly pro každý z objektů vypočítány semivariogramy a extrahován soubor geostatistických příznaků. Výběr vhodných příznaků, které byly použity jako vstup do klasifikátoru Random Forest, proběhl na základě analýzy hlavních komponent. Testován byl výběr spektrálních a geostatistických příznaků. Využití semivariogramu se ukázalo jako vhodné pro charakteristiku prostorové heterogenity. Výsledky ukázaly, že lepších klasifikačních výsledků lze dosáhnout kombinací geostatistických a spektrálních příznaků.

Kombinaci spektrálních a texturálních proměnných v klasifikátoru RF využil také Rodriguez-Galiano et al. (2015a) pro klasifikaci středomořské vegetace v provincii Granada na jihu Španělska. Jedná se o území, které se vyznačuje vysokým množstvím vegetačních kategorií, které jsou od sebe velmi obtížně odlišitelné. Hlavním cílem studie bylo zhodnotit vhodnost užití geostatistických texturálních proměnných, a to jak multitemporálních, tak i těch získaných z jednoho termínu. Jako vstupní data posloužily snímky Landsat 5 z měsíců dubna a srpna roku 2004. Klasifikační legenda čítala 14 kategorií a jako vstup do klasifikace bylo vytvořeno celkem 971 potenciálních vstupních proměnných. Jako nejdůležitější pro celkovou přesnost klasifikace se ukázaly variogramy v oblasti viditelného a blízkého infračerveného pásma, které zohledňují důležitou informaci o sezónním chování vegetace. Pro odlišení zemědělských tříd pak vykazaly důležitost multitemporální variogramy. Nejlepší klasifikační výsledky byly dosaženy kombinací 16 nejdůležitějších texturálních příznaků. Popsanou metodou bylo dosaženo výrazně vyšší přesnosti (92 %) než v případě klasifikátoru Maximum Likelihood.

Gao et al. (2015) se ve své studii zabýval mapováním březových porostů v severní Číně. Využitím multitemporálních texturálních, spektrálních a topografických příznaků bylo

dosaženo klasifikační přesnosti 93 %.

Objektový přístup v kombinaci s klasifikátorem Random Forest využil Yin et al. (2018) k analyzování procesu opouštění zemědělské půdy v oblasti Kavkazu. Využito bylo časové řady dat Landsat z let 1984 až 2018. V první řadě byla v softwaru eCognition provedena prostorová segmentace multitemporálního kompozitu z let 1989, 1998, 2007 a 2015. Následně byla vypočítána pravděpodobnost výskytu zemědělské půdy pro každý pixel pomocí algoritmu Random Forest. Jako vstupní proměnné do výpočtu byly vybrány průměr, medián, směrodatná odchylka, 25 percentil a 75 percentil. Ty byly vypočítány z časových řad snímků pro jednotlivé roky. Dále byla aplikována časová segmentace, která sloužila k detekci změn. Pixelové pravděpodobnosti byly agregovány segmentovanými objekty vypočítáním hodnoty mediánu. Nakonec byly vypočítány přesnosti jednotlivých klasifikací a porovnán objektový a pixelový přístup. Bylo zjištěno, že objektovým přístupem lze dosáhnout výrazně lepších výsledků (celková přesnost 97 %) v porovnání s pixelovým přístupem (82 %).

Marcinkowska-Ochytra et al. (2018b) využila klasifikátoru RandomForest ke klasifikaci oblasti vegetace v chráněné oblasti Natura 2000 v horním Slezsku v okolí města Jaworzno. Cílem studie bylo klasifikací spolehlivě oddělit expanzivní travní druhy třtina křovištní a bezkolenec modrý. Využito bylo hyperspektrálních dat HySpex s prostorovým rozlišením 1 m a 470 spektrálními pásmy a dat z LIDARu. K dispozici byla data ze 3 termínů snímání z měsíců června, srpna a září. Na hyperspektrálních snímcích byla provedena Minimum Noise Fraction (MNF) transformace a pro klasifikaci vybráno 30 pásem. Vypočítáno bylo také 65 různých vegetačních indexů. Z LIDARových dat byl vygenerován digitální vegetační model, topografické indexy a další charakteristiky sledované vegetace. Tyto proměnné vytvořily celkem 9 různých kombinací vstupních proměnných, pro které byly testovány klasifikace. Parametr ntree (počet stromů) byl nastaven na 100 a mtry (počet vstupních proměnných, ze kterých je náhodně vybíráno v každém uzlu) byl zvolen jako odmocnina z počtu vstupních proměnných. Klasifikace proběhla pro oba sledované vegetační druhy zvlášť. Klasifikace byly hodnoceny pomocí Kappa koeficientu a vypočítána byla také uživatelská a zpracovatelská přesnost. Výsledky ukázaly, že v případě aplikace MNF transformace bylo dosaženo vyšší přesnosti v porovnání s použitím původních spektrálních pásem. Nejvyšší přesnosti klasifikace bylo dosaženo pro kombinaci všech vypočítaných vstupních proměnných. Vyšší přesnosti klasifikace byly zjištěny pro bezkolenec modrý než pro třtina křovištní. Jako nejlepší termín pro rozlišení třtiny byl zjištěn zářijový termín snímání, pro bezkolenec modrý potom srpnový. Za nejlepší dobu pro odlišení těchto travin lze obecně označit dobu kvetení. V této části vegetační sezóny dochází k vysokému procentu pokrytí polygonu (80 % - 100 %). Lepší výsledky klasifikace by pravděpodobně mohl přinést detailnější analýza a následný výběr nejdůležitějších proměnných.

Různé výzkumy využívají v klasifikačním procesu různý počet rozhodovacích stromů (*ntree*). Jak uvádí Rodriguez-Galiano et al. (2012a), vhodnost volby tohoto parametru je závislá na mnoha kritériích, které je nutno brát v potaz. Jedním z nejdůležitějších je počet vstupních proměnných. Například Gao et al. (2015) pro mapování březových porostů testoval různé počty rozhodovacích stromů a došel k závěru, že přesnost klasifikace se v jeho případě zvýšila s rostoucím počtem rozhodovacích stromů. Marcinkowska-Ochytra et al. (2018b) zvolila při klasifikaci travní vegetace 100 vstupních stromů, zatímco Rodriguez-Galiano et al. (2012a) klasifikoval středomořskou vegetaci s nastavením na 5000 vstupních stromů. Všechny výše zmíněné studie dosáhly uspokojivých výsledků.

Jedním z hojně využívaných příznaků, které v rámci klasifikace Random Forest ve zmíněné literatuře přináší dobré klasifikační výsledky, je textura.

2.2.1.1 Textura

Textura je interpretační znak, který popisuje tónovou proměnlivost částí obrazu, který vytváří charakteristický vzorek. Jedná se o kvalitativní parametr, jehož definice vychází z výpočtu různých statistických měr homogenity nebo variability hodnot všech pixelů v rámci filtrovacího okna (Dobrovolný, 1998).

Podle Rodriguez-Galiano et al. (2012a) může být zařazení texturálních proměnných do klasifikačního procesu velmi přínosné zejména v případě, kdy jsou sezónní změny mezi jednotlivými typy krajinného pokryvu důležité pro jejich odlišení. K měření textury existují různé přístupy. Tím nejvyužívanějším v rámci oboru dálkového průzkumu Země jsou podle Rodriguez-Galiano et al. (2012a) statistiky odvozené z Grey-Level -Co-Occurrence Matrix (GLCM). Tato metoda, která pracuje na principu využití vztahu mezi sousedními pixely, je v rámci problematiky klasifikace krajinného pokryvu velmi rozšířená. GLCM je čtvercová matice (viz Obr. 1), která podává informaci o tom, jak často se pixel s odstínem šedi o hodnotě i vyskytuje v daném prostorovém vztahu k pixelu s odstínem šedi o hodnotě j . Každý element výsledné matice je tedy suma četnosti výskytu pixelu s hodnotou i vyskytujícího se v daném prostorovém vztahu k pixelu s hodnotou j (Mathworks, 2019). Mezi nejvyužívanější texturální charakteristiky, které je možné na základě GLCM vypočítat, se řadí kontrast, nepodobnost, homogenita, entropie, průměr, rozptyl korelace a druhý úhlový moment.

2.2.3 Support Vector Machine

Jedná se o metodu strojového učení, která pracuje na principu tzv. strukturální minimalizace rizika (Vapnik, 1998). Podle Petropoulos et al. (2012) se stejně jako v případě Neural Network jedná o neparametrický klasifikátor, který nevyžaduje normální rozdělení dat. Podstatou algoritmu Support Vector Machine (SVM) je podle Gidudu, Hulley, Marwala (2007) převedení vstupního prostoru do prostoru vícedimenzionálního, který umožňuje oddělení tříd. Pomocí algoritmů jsou nalezeny lineární hranice a reprezentovány nelineární funkce. Zhu, Blumberg (2002) uvádí, že principem SVM je snaha o nalezení ideální nadroviny, která oddělí data do zadaného počtu tříd, které odpovídají trénovacím množinám. Optimální nadrovinu definuje jako tu, ve které minimum vzdáleností bodů od roviny je co největší a tyto body (trénovací data, která náleží odlišným třídám) leží v opačných poloprostorech. Nejbližší body se nazývají podpůrné vektory (support vectors).

2.3 Multitemporální přístup ke klasifikaci

Protože přírodní procesy jsou velmi časově proměnlivé, (barevné změny, fenologické fáze ve vegetačním období atd.), jejich průběžné sledování může napomoci ke zpřesnění klasifikačních výsledků. Družice snímají zájmové území v pravidelných časových intervalech a dávají nám tak možnost získat přesnější informaci o sledovaných objektech. Multitemporální přístup vychází z klasifikace časové řady dat, která mohou být spojena do jednoho multitemporálního datasetu. Ten obsahuje kombinaci spektrálních pásem v závislosti na spektrálním rozlišení vstupních dat (Dobrovolný, 1998). Dle Lu et al. (2004) multitemporální přístup zkoumá změnu spektrálních charakteristik sledovaných objektů. Usiluje o lepší odlišení vybraných prvků na základě informací z více časových období, což může vést ke zlepšení přesnosti klasifikace. Zejména díky rozvoji informačních technologií lze kromě multitemporálních syntéz využít i další přístupy, které pracují s multitemporálními daty. Mezi základní lze zařadit obrazové rozdíly, regresní analýzu, porovnání výsledků klasifikace, či analýzu vektoru spektrální změny (Dobrovolný, 1998).

2.4 Klasifikace v tundře

Studie uvedené v této kapitole se zabývají klasifikací vegetačního pokryvu v alpské tundře na území České republiky a Polska. Jsou vybrány z důvodu využití podobných klasifikačních metod, využitých dat a klasifikační legendy jako v této diplomové práci.

Král (2009) využil ortofoto v infračerveném pásmu s prostorovým rozlišením 0,9 m ke klasifikaci vegetačního pokryvu v Národní přírodní rezervaci Praděd v CHKO Jeseníky. Hlavním objektem zájmu byly přechodné zóny mezi subalpínskými lesy a alpskou tundrou. Klasifikátorem MLC bylo hodnoceno sedm kategorií (antropogenní plochy, pastviny a holé plochy, kleč, listnaté stromy, smrkové kultury, stojící suché smrky a úlomky a skalní výchozy) s celkovou přesností 78 %.

Zagajewski et al. (2005) se zabýval klasifikací vegetace v subalpínském, alpínském a subniválním pásmu ve východní části Tatranského národního parku. Klasifikovány byly hyperspektrální letecké snímky ze sensorů DAIS 7915 se 79 spektrálními pásmy a prostorovým rozlišením 3 m, dále pak senzorem ROSIS se 115 spektrálními pásmy a rozlišením 1 m. Provedena byla neřízená klasifikace a řízená klasifikace MLC a NN. Do té vstupovalo sedm kategorií krajinného pokryvu (kosodřevina, lesy, louky, skály, jezera, stíny a turistické trasy). Klasifikace MLC pro sensor DAIS proběhla dvakrát, jednou pro všechna pásma snímku, podruhé s vybranými pásmy. V prvním případě celková přesnost dosáhla 78 %, v druhém byla přesnost nižší, pouze 71 %. Výsledky klasifikací byly porovnány s botanickými mapami, které vznikly na základě terénního průzkumu. Autor uvádí, že lepších výsledků by mohlo být dosaženo zahrnutím jiných než spektrálních vlastností snímku do klasifikace (např. textura).

Jędrych et al. (2017) se zabýval vhodností využití satelitních snímků Sentinel-2 a hyperspektrálních dat EnMAP, které nabízí spektrální rozlišení 242 pásem a prostorové 30 m, pro klasifikaci alpínské a subalpínské vegetace v Krkonoších. Klasifikace probíhala pro 7 kategorií vegetačního pokryvu a porovnány byly klasifikátory SVM, RF a MLC. Nejvyšší klasifikační přesnosti (82 %) bylo v případě dat Sentinel-2 dosaženo klasifikátorem SVM pro 6 pásem PCA a pro data EnMAP se s využitím stejného klasifikátoru jako nejvhodnější ukázal vstup všech pásem (83 %). Vzhledem k nízkému prostorovému rozlišení dat bylo nejproblematictější rozlišení heterogenních travních kategorií. Jejich uživatelská a zpracovatelská přesnost se pohybovala pod 50 %.

2.5 Klasifikace v krkonošské tundře

Krkonošskou tundru v okolí Labské boudy studovala Mullerová (2005). Hodnoceny byly multispektrální letecké snímky (s červeným, zeleným, modrým a infračerveným pásmem) z let 1986, 1989 a 1977 s prostorovým rozlišením 1 m. Pro účely lepšího odlišení bylo využito technik vyrovnání histogramu, PCA a NDVI. Provedeny byly řízená a neřízená klasifikace. Klasifikátorem ISODATA, v případě neřízené klasifikace, bylo dosaženo přesnosti 63 % a odlišit se podařilo 6 tříd (kosodřevina, smilka tuhá, vysoké trávy a bylinná společenstva, vegetace podél silnic s vysokými trávami a bylinnými společenstvími, silnice nebo společenstva smilky a silnice nebo nízké trávy a byliny (metlice trsnatá)). Nejvíce problematické se ukázalo rozlišení silnice a smilky. Řízenou klasifikací metodou MLC bylo rozlišeno 7 kategorií a dosaženo konečné přesnosti 79 %.

Marcinkowska-Ochytra et al. (2018a) hodnotila přesnost klasifikace rozlehlé části území Krkonošského národního parku, které se nachází na česko-polské hranici. Pomocí hyperspektrálních dat APEX s 288 spektrálními pásmy za použití klasifikátoru Support Vector Machine (SVM) proběhla klasifikace pro 22 kategorií vegetačního pokryvu. Pro "zhuštění" informace v obraze byla aplikována MNF a PCA transformace a testovány přesnosti pro jednotlivé vstupy. Jako referenční data byla

využita kombinace vegetačních map, terénních polygonů a ploch, které vznikly vizuální interpretací nad ortofotem. Nejvyšší celkové přesnosti klasifikace (84 %) bylo dosaženo s využitím 40 pásem PCA. 14 z celkového počtu kategorií bylo klasifikováno s více než 80 % uživatelskou přesností a 16 tříd s více než 80 % zpracovatelskou přesností. Bylo zjištěno, že data Apex a klasifikátor SVM jsou vhodná pro klasifikaci vegetace v tundře.

Vhodností dat WorldView pro klasifikaci vegetace nad horní hranicí lesa v krkonošském národním parku se zabývala Pomahačová (2012). Klasifikační legenda obsahovala 8 kategorií vegetačního pokryvu a porovnány byly metody Maximum Likelihood a Neural Network. Pro zhodnocení významu spektrálních pásem bylo využito diskriminační analýzy. Nejvyšší přesnosti dosáhla metoda neuronových sítí. Jako návrh na vylepšení přesnosti klasifikace autorka uvádí objektovou klasifikaci.

Suchá et al. (2016) ke klasifikaci vegetace na území krkonošské tundry využila leteckých ortofot, družicových dat Worldwiew – 2 a Landsat 8. Klasifikační přesnosti byly následně porovnány. Letecká ortofota s prostorovým rozlišením 12,5 m a čtyřmi spektrálními pásmy byla klasifikována objektovým přístupem. Pro data WorldWiew- 2, s prostorové rozlišení 2 m a 8 spektrálními pásmy, proběhla jak pixelová, tak objektová klasifikace. Data Landsat 8, která mají prostorové rozlišení 30 m a 7 spektrálních pásem, byla klasifikována pouze pixelově. Testovány byly klasifikační metody MLC, SVM a NN. Územím zájmu byly 2 oddělené oblasti – východní a západní část krkonošské tundry. Pro obě část proběhla klasifikace pouze v případě dat Landsat 8, pro ostatní data byly z důvodu náročnosti zpracování hodnoceny pouze vybrané části území. Detailní legenda čítá 12 kategorií krajinného pokryvu (kamenná moře a antropogenní plochy, smrkové porosty, kosodřevina, subalpínská brusnicová vegetace, alpínské trávníky zapojené – smilka tuhá, druhově bohaté porosty s vysokým zastoupením dvouděložných, subalpínské vysokostébelné trávníky – třtina chloupkatá, bezkoleneček modrý, metlice trsnatá, subalpínské vysokobylinné trávníky, alpínská vřesoviště, mokřady a rašeliniště, vodní plochy). V případě dat Landsat 8 bylo nutné vytvořit i legendu zjednodušenou, protože některé vegetační třídy se často vyskytují na plochách, které jsou menší než pixel Landsatu. Detailní legenda byla proto využita pouze pro ortofota a data World-View 2 v oblasti západní tundry. Nejlepších výsledků bylo dosaženo objektovou klasifikací ortofota metodou SVM (celková přesnost dosáhla 71 %). S nejvyšší přesností byly klasifikovány nevegetační třídy, kosodřevina a brusnicová vegetace. Nejnižší celkové přesnosti naopak dosáhly kategorie subalpínských vysokostébelných trávníků.

Kupková et al. (2017) porovnává hyperspektrální letecká ortofota pořízená sensory AISA Dual, APEX a družicová data Sentinel 2. Pixelovým i objektovým přístupem byla klasifikována data AISA Dual s prostorovým rozlišením 1-3 m a 494 spektrálními pásmy a data APEX, která mají prostorové

rozlišení 3-5 m a 288 spektrálních pásem. Data Sentinel-2, která mají rozlišení 10 m a 20 m a využito bylo 10 spektrálních pásem, byla klasifikována pouze pixelově. Využita byla jak detailní, tak zjednodušená legenda. Nejlepší celkové přesnosti bylo dosaženo pro data AISA Dual klasifikátorem SVM (84,3 %). Naopak nejhorší výsledek byl zaznamenán v případě dat Sentinel-2, kdy největší přesnosti (58 %) bylo dosaženo metodou NN. Tento výsledek odpovídá předpokladu nízké klasifikační přesnosti, protože velikost pixelu u Sentinelu, stejně tak jako u Landsatu, nevyhovuje požadavkům detailní legendy. Problematické nebylo, shodně s daty World-View 2 a Landsat 8, rozlišení kosodřeviny a kamenných moří a antropogenních ploch. V případě Sentinelu byla s nejnižší přesností klasifikována třída bezkolenec modrý, u kterého často docházelo k záměně s metlicí trsnatou nebo subalpínskou brusnicovou vegetací. Nízké přesnosti byly dosáhly také alpská vřesoviště, třtina chloupkatá a smilka tuhá. Tyto vegetační třídy, které se řadí do kategorie subalpínských vysokostébelných trávníků, mají podobný spektrální signál a snadno tak dochází k jejich záměně. Celková přesnost klasifikace dat Sentinel-2 pro zjednodušenou legendu dosáhla 77,7 %.

2.6 Klasifikace dat PlanetScope

Přestože jsou družicové snímky PlanetScope relativně novým zdrojem dat, v současné době již existuje poměrně velké množství studií, které těchto produktů využívají. Níže uvedené práce testují jejich vhodnost pro klasifikaci vegetačního pokryvu. Uváděny jsou z důvodu využití obdobných metod jako v této diplomové práci (klasifikátor Random Forest, hodnocení kvality dat atmosféricky korigovaných společností Planet).

Choi, Yoon (2018) využili dat PlanetScope k hodnocení změn a aktualizaci map krajinného pokryvu poblíž města Seyong na území Jižní Korey. Jako vstup do klasifikace bylo využito 3 snímků PlanetScope úrovně 1B pořízených v září 2016. Atmosférické korekce byly provedeny pomocí modulu QUAC v softwaru ENVI. Pro porovnání klasifikačních výsledků a zjištění změny krajinného pokryvu byla využita existující mapa krajinného pokryvu shodného území z roku 2013. Klasifikováno bylo 5 tříd krajinného pokryvu (zástavba, les, pole, rýžová pole a vodní plochy). Využito bylo pixelové klasifikace Random Forest a pro lepší identifikaci vodních ploch byly do klasifikace byly zahrnuty také indexy NDVI a NDWI. Výsledky, které dosáhly přesnosti 95,5 %, potvrdily, že data PlanetScope jsou vhodná ke klasifikaci vegetačního pokryvu.

Traganos, Reinartz (2018) s pomocí multispektrálních dat RapidEye mapovali změny výskytu mořských řas v oblasti Soluňského zálivu. Využita byla časová řada dat z let 2011-2016, která byla klasifikována metodou Random Forest. Protože zjištěné výsledky odpovídají obecnému trendu o změnách výskytu mořských řas ve středomoří, autoři shledávají použitou metodu, i vzhledem k její

přesnosti a časové a finanční nenáročnosti, vhodnou pro mapování analyzování nejen středomořské pobřežní vegetace.

Klasifikací mořské vegetace se zabývali také Wicaksono, Lazuardi (2018), kteří využili kombinace vysokého prostorového a časového rozlišení dat PlanetScope k mapování v oblasti indonéskeho souostroví Karimunjawa. Využito bylo dvou snímků PlanetScope z května a srpna 2017. Provedeny byly PCA, MNF a LSU transformace. Následně proběhla pixelová (MLC, SVM a CTA) a objektová klasifikace. 5 kategorií vegetace bylo klasifikováno s nejvyšší přesností 74,31 %. Autoři zmiňují, že výsledky jsou srovnatelné s ostatními daty s vysokým prostorovým rozlišením a domnívají se, že data PlanetScope jsou díky jejich vysokému časovému rozlišení vhodná pro monitoring změn nejen pobřežní vegetace.

Asrat et al. (2018) porovnával vhodnost satelitních dat s různým spektrálním, časovým a prostorovým rozlišením pro mapování lesních porostů v Etiopii. Hodnoceno bylo 7 oblastí, které se lišily rozlohou a vegetačními podmínkami. Výsledky ukázaly, že data PlanetScope a RapidEye s vysokým prostorovým rozlišením, přinesly, v porovnání s ostatními testovanými daty, lepší výsledky.

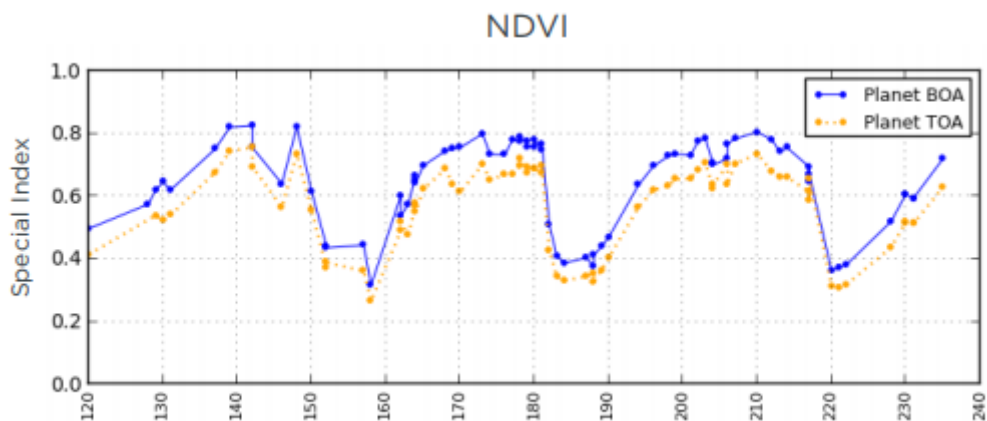
2.7 Atmosférické korekce

Jak uvádí Dobrovolný (1998), efekty atmosféry, zejména procesy pohlcování a rozptylu, způsobují, že naměřené hodnoty zářivých vlastností objektů na povrchu Země neodpovídají jejich vlastnostem ve skutečnosti. Hlavním cílem atmosférických korekcí je získání absolutních hodnot odrazivosti z hodnot naměřených radiometrem družice. Podle Songa et al. (2001) není nutné provádět atmosférické korekce, pokud jsou multitemporální data v jednom datasetu a trénovací plochy vybírány nad všemi pásmy. Stejně tak tomu je i v případě klasifikace jednoho termínu. Korekce jsou naopak vyžadovány v případě výpočtu NDVI.

2.7.1 Atmosférické korekce dat PlanetScope


Společnost Planet využívá k atmosférické korekci modelu 6SV2.1. Atmosféricky korigované produkty jsou označovány jako Analytic (Surface Reflectance) a jsou odvozeny z produktu Analytic (Radiance).

Vhodnost využití atmosféricky korigovaných dat PlanetScope je hodnocena v Planet (2018). Hodnocení proběhlo na základě sledování spektrálních vlastností zemědělských plodin v rámci vybraného území v průběhu letních měsíců sezóny 2017. K analýze byla vybrána časová řada snímků PlanetScope zachycující vybrané pole v rámci zemědělské oblasti v Sacramento Valley v Kalifornii. Z těchto dat byly vypočítány vegetačních indexy NDVI a EVI a zjištěny také hodnoty odrazivosti v jednotlivých spektrálních pásmech. Nejprve byly porovnány hodnoty pro data před a po atmosférické korekci (viz Obr. 2).

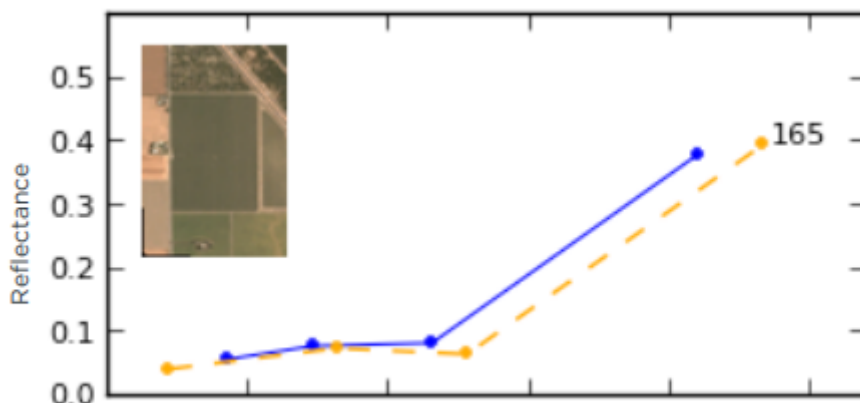


Obr. 2: Porovnání hodnot EVI dat PlanetScope před a po atmosférické korekci (zdroj: Planet Surface Reflectance Product, 2018)

Hodnoty před provedením atmosférické korekce dokazují důležité efekty způsobené atmosférou. Špičaté tvary křivky hodnot před atmosférickou korekcí znázorňují mraky, které způsobují efekty atmosférického rozptylu. Z Obr. 3 je také zřetelná vhodnost využití husté časové řady, kterou data PlanetScope poskytují, ze které je jasně viditelný prudký pokles hodnot NDVI v průběhu období sklizně. Následně byly hodnoty vypočítaných ukazatelů porovnány s odpovídajícími daty Landsat 8 Surface Reflectance Product (viz Obr. 4).



Obr. 3: Porovnání hodnot EVI dat PlanetScope a Landsat po atmosférické korekci (zdroj: Planet Surface Reflectance Product, 2018)



Obr. 4: Porovnání hodnot odrazivosti da PlanetScope a Landsat po atmosférické korekci v pásmech Blue, Green, Red a NIR, (zdroj: Planet Surface Reflectance Product, 2018)

Výsledky ukázaly, že hodnoty vypočítané na základě dat PlanetScope jsou velmi podobné hodnotám dat Landsat 8. Z Obr. 3 je také zřetelná výhoda vyššího časového rozlišení dat PlanetScope pro účely multitemporální analýzy oproti datům Landsat 8, která mají nižší časové rozlišení. Autoři konstatují, že Surface Reflectance Product je konzistentní s ostatními atmosféricky korigovanými datasey a byla potvrzena vhodnost užití Surface Reflectance Product pro účely multitemporálních analýz.

3 Zájmové území

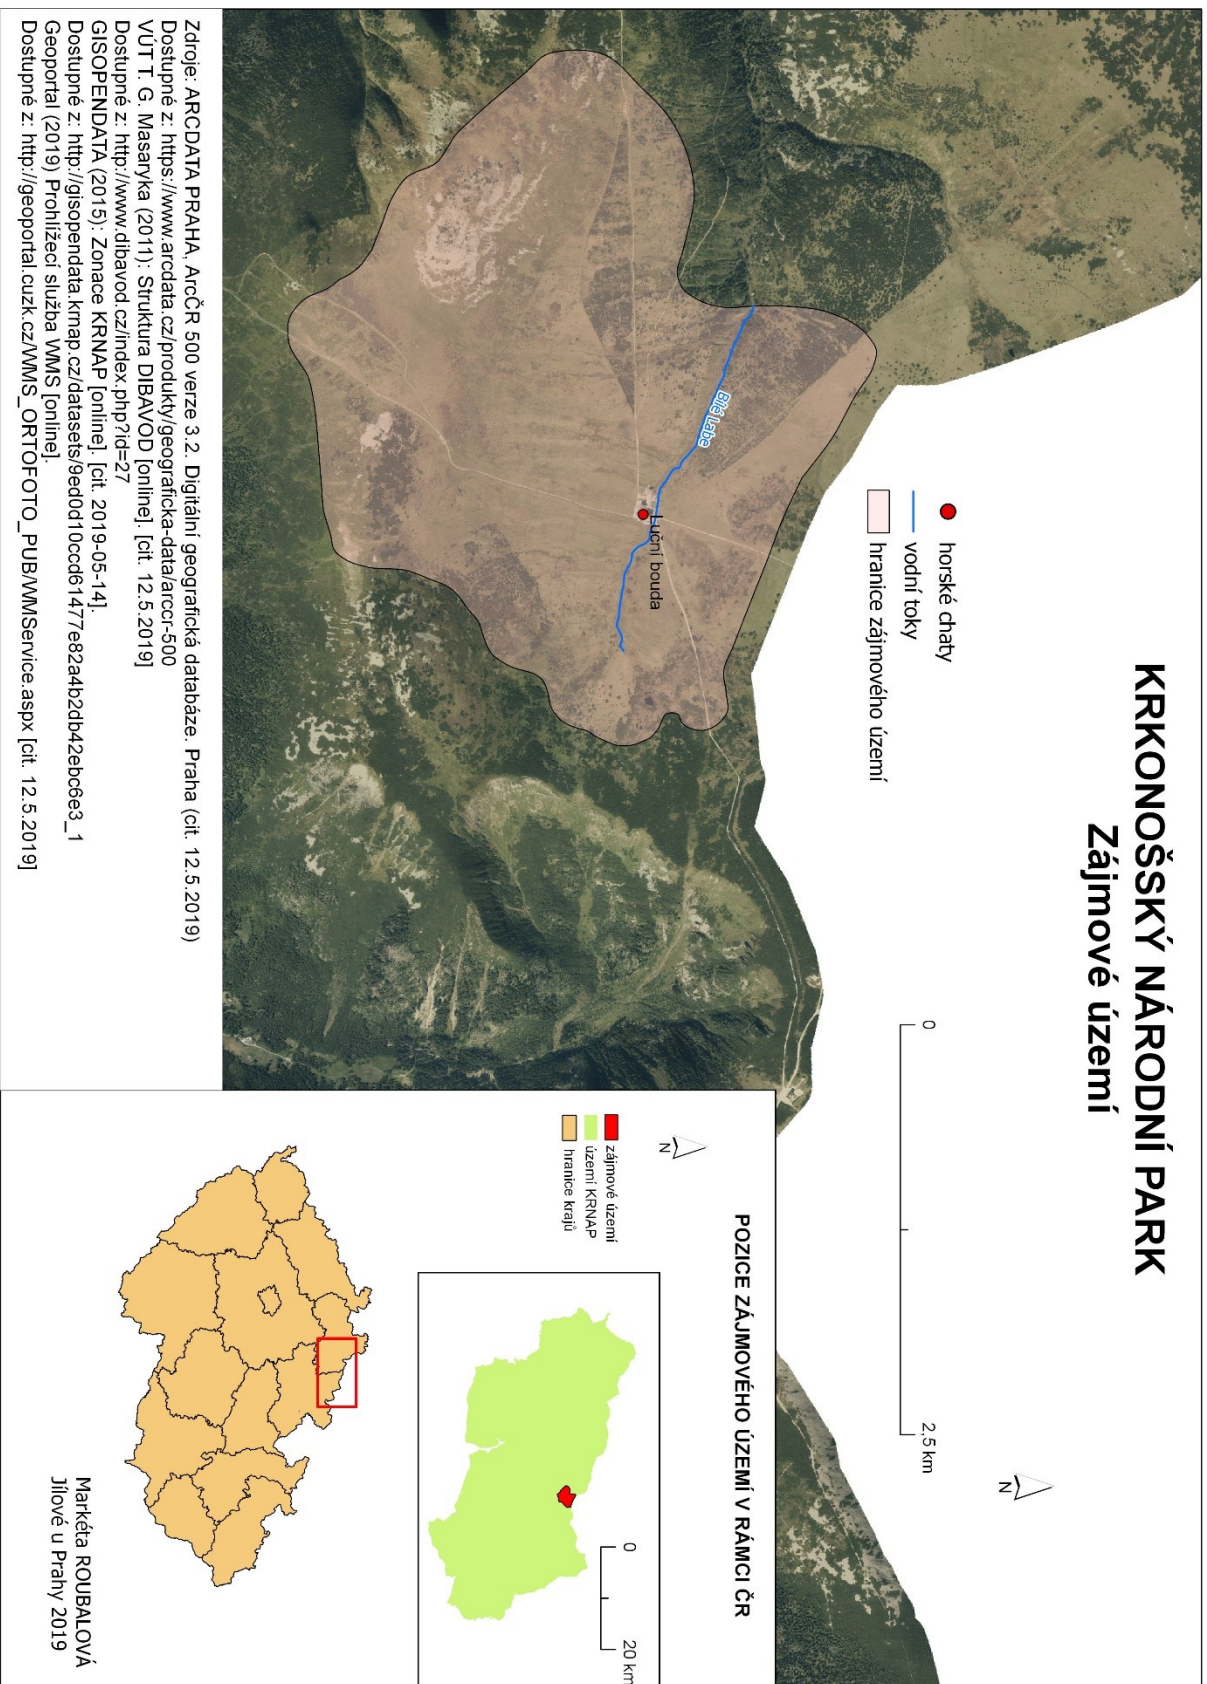
Zájmové území se nachází ve východní části krkonošské tundry v okolí Luční boudy. Rozkládá se v 1. zóně krkonošského národního parku a jeho rozloha je 3,5 km² (viz Obr. 5). Pokud bychom brali v úvahu i západní část krkonošské tundry, zaujímá zájmové území 7 % z celkové rozlohy krkonošské tundry (KRNAP, 201?).

Území se nachází nad horní hranicí lesa a jeho průměrná nadmořská výška dosahuje 1452 m n. m. Jak uvádí Soukupová et al. (1995), jedná se o území s průměrnou roční teplotou od 0 °C do +1 °C a průměrným ročním úhrnem srážek 1 400 mm. Průměrné denní teploty nad 0 °C se vyskytují velmi zřídka a území je v průměru 180 dní pokryto sněhovou pokrývkou. V nejvyšších partiích má na charakter území velký vliv činnost větru. Co se týče vegetace, kromě mechů, lišejníků a alpínských vřesovišť jsou převládajícími typy alpínské trávníky s vysokým zastoupením smilky tuhé, subalpínské vysokostébelné trávníky a kleč (Chytrý et al. 2001). Poměry zastoupení jednotlivých druhů se v průběhu času mění. Podle nedávných pozorování dochází k rozšiřování druhů bezkoleneček modrý a třtina chloupkatá. Výskyt vegetačních typů úzce souvisí s vývojem Krkonoš během dob ledových. V těchto dobách působily jako přechodná zóna mezi biotou skandinávské tundry a alpínskými loukami. Jeník and Štursa (2003) toto území označuje jako křižovatku biodiverzity.

Od středověku až do začátku 19. století bylo území významně ovlivňováno lidskou činností. V rámci tzv. budního hospodářství, které se začalo formovat v první polovině 17. století, docházelo ve velké míře k odlesňování a pastvě dobytka v oblasti horní hranice lesa. Od konce 18. století bylo území výrazně ovlivňováno rozvojem turistiky. V současné době se již jedná o přísně chráněné území a k zásahům člověkem tak dochází minimálně. Vegetace může být ovlivňována spíše lavinami a sesuvy půdy (KRNAP, 201?).

KRKONOŠSKÝ NÁRODNÍ PARK

Zájmové území



Obr. 5: Mapa zájmového území (vlastní zpracování)

3.1 Hodnocené kategorie vegetačního pokryvu

Mezi analyzované kategorie vegetačního pokryvu byly zařazeny smilka tuhá (*Nardus stricta*), třtina chloupkatá (*Calamagrostis villosa*) a bezkolenec modrý (*Molinia caerulea*). Protože tyto druhy trav mají obecně velmi podobný spektrální projev, je důležité testovat předpokládané rozdíly v jejich spektrálním projevu dané do určité míry odlišnými fenologickými fázemi, případně jejich posunem v průběhu vegetační sezóny a tedy to, kdy je spektrální odezva každého jednotlivého druhu jedinečná v porovnání se dvěma dalšími druhy a ostatní okolní vegetací.

Bezkolenec modrý

Bezkolenec modrý (*Molinia caerulea*) tvoří trsy o průměru až 30 cm a dorůstá výšky kolem 120 cm (Kubát et al., 2002). Vyskytuje se na zamokřených půdách pod hranami karů a vyhledává slunečná stanoviště. V červnu obsahuje vysoký podíl sušiny a v průběhu července se zbarvuje do zelena. Kvete na přelomu července a srpna. Koncem vegetační sezóny, v druhé polovině srpna a v průběhu září, získávají konce bezkolence až hnědou barvu (Kočí, 2001a). Vývoj v průběhu sezóny je zobrazen na Obr. 6.



Obr. 6: Změny bezkolence modrého v průběhu vegetační sezóny v termínech 15.6.2017, 28.6.2017, 4.8.2016, 29.8.2014, 17.8.2015 (pořadí zleva), foto: Lucie Červená

Smilka tuhá

Smilka tuhá (*Nardus stricta*) tvoří trsy, které dorůstají výšky 5-30 cm (Kočí, 2001). V červnu obsahuje vysoký podíl sušiny, v průběhu července její tenké listy dostávají šedozelenou barvu. Koncem srpna se zbarvuje do žluta. Vývoj smilky v průběhu sezóny je zobrazen na Obr. 7.



Obr. 7: Změny smilky tuhé v průběhu vegetační sezóny (červen-srpen) v termínech 15.6.2017, 28.6.2017, 6.8.2016, 16.8.2015, 28.8.2014 (pořadí zleva), foto: Lucie Červená

Třtina chloupkatá


Třtina chloupkatá (*Calamagrostis villosa*) kvete od června do července výraznými šedavými až nafialověle růžovými latami, které v suchém stavu často vydrží až do jara (Pyšek, 1993). Raší brzo, někdy už v průběhu března. Počátkem června se vyznačuje výraznou zelenou barvou, přičemž její konce mohou být lehce zbarveny do fialova. V průběhu srpna se její listy zbarvují do červeno-fialové. Vývoj v průběhu sezóny je zobrazen na Obr. 8.



Obr. 8: Změny třtiny chloupkaté v průběhu vegetační sezóny (červen-srpen) v termínech 15.6.2017, 27.6.2014, 6.8.2016, 17.8.2015, 28.8.2014 (pořadí zleva), foto: Lucie Červená

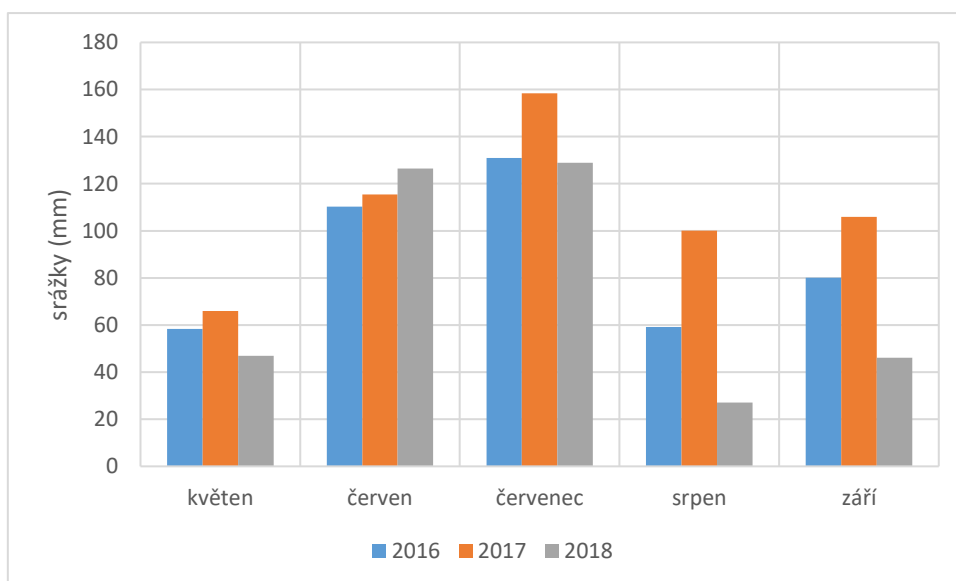
3.2 Průběh počasí ve sledovaných letech

Pokud se týká počasí, sezóny 2016, 2017 a 2018, pro něž jsou v této práci použita data PlanetScope, jsou od sebe velmi odlišné. Pro rok 2018 je charakteristický brzký nástup vysokých teplot (Obr. 9), jejichž měsíční průměr byl zejména v květnu a srpnu oproti ostatním sezónám výrazně vyšší. Nejnížší průměrné teploty byly zaznamenány v sezóně 2017, nejvyšší naopak v sezóně 2018.




Obr. 9: Průměrná teplota vzduchu na Sněžce od května do září v letech 2016, 2017 a 2018 (zpracováno dle Meteomanz, 2019)

Obr. 10 ukazuje, že nejvíce srážek spadlo v sezóně 2017, nejméně naopak v sezóně 2018. Nejdeštivějším měsícem byl v případě všech sledovaných let červenec.



Obr. 10: Měsíční úhrn srážek na Sněžce od května do září v letech 2016, 2017 a 2018 (zpracováno dle Meteomanz, 2019)

Jak je zřejmé z Obr. 11, v dubnu 2018 bylo v porovnání s lety 2016 a 2017 zaznamenáno velmi málo dní s výskytem sněhových srážek, což patrně souvisí s rychlým nástupem vysokých teplot v tomto roce. Naopak pro září 2018 jsou charakteristické spíše nižší teploty a oproti roku 2016 vyšší počet dní s výskytem sněhových srážek.



Obr. 11: Počet dní s výskytem sněhových srážek na Sněžce v letech 2016, 2017 a 2018 (zpracováno dle Meteomanz, 2019)

4 Data a metodika


4.1 Data

4.1.1 Data systému družic PlanetScope

Americká společnost Planet Labs Inc. byla založena v roce 2010 a v současnosti provozuje největší systém družic na světě. Společnost je specifická svým přístupem, kdy ke snímkování využívá velkého množství malých družic Dove, které se na oběžnou dráhu dostávají pomocí sdílených startů. Systém družic PlanetScope je tvořen 175 družicemi Dove. Vyznačuje se unikátním časovým rozlišením, kdy jako první a jediná soustava družic na světě dokáže jednou za den nasnímat celý zemský povrch. První družice Dove se na oběžnou dráhu dostaly v roce 2013 a jejich počet se stále zvyšuje. V modrém, zeleném, červeném a blízkém infračerveném spektru disponují prostorovým rozlišením 3 metry. Snímky nacházejí využití například v lesnictví, zemědělství, při monitorování přírodních katastrof či urbanizace. Díky výbornému časovému rozlišení se jedná o vhodný zdroj dat pro časové řady (Planet, 2018). Další parametry družice jsou uvedeny v Tab. 1.

označení pásma	název pásma	prostorové rozlišení (m)	rozsah od [nm]	rozsah do [nm]
1	Blue	3	455	515
2	Green	3	500	590
3	Red	3	590	670
4	NIR	3	780	860

Tab. 1: Spektrální pásma PlanetScope (zpracováno dle Planet, 2018)



Obr. 12: Družice PlanetScope (Gisgeography, 2019)

Z archivu dat PlanetScope <https://www.planet.com/explorer/> bylo vybráno 12 bezoblačných termínů z let 2016, 2017 a 2018, které uvádí Tab. 2. Využito bylo dat úrovně 3B, která poskytuje

radiometricky i atmosféricky korigovaná data (produkt *Analytic Surface Reflectance*). Pro termín 21.6.2017 a 28.8.2016 ale Surface Reflectance produkty nebyly dostupné, a proto byla atmosférická korekce provedena pomocí modulu QUAC v ENVI 5.3. (viz kapitola 4.2.1).

Termín snímání
7.6.2018
21.6.2017
7.7.2018
22.7.2018
30.7.2017
7.8.2018
20.8.2018
27.8.2018
28.8.2016
5.9.2017
8.9.2016
10.9.2018

Tab. 2: Bezoblačné termíny dat PlanetScope využité pro klasifikaci a spektrální analýzu

4.1.2 Data družic RapidEye

Jedná se o soustavu pěti identických družic společnosti Planet Labs Inc., které snímají zemský povrch od roku 2008 (Obr. 13). Jejich prostorové rozlišení je 5 m a disponují červeným, zeleným, modrým, red edge a blízkým infračerveným pásmem. Atmosférické korekce byly provedeny pomocí modulu QUAC v ENVI 5.3. (Planet, 2018). Další parametry družice jsou uvedeny v Tab. 3.

označení pásma	název pásma	prostorové rozlišení (m)	rozsah od [nm]	rozsah do [nm]
1	Blue	5	440	510
2	Green	5	520	590
3	Red	5	630	685
4	Red edge	5	690	730
5	NIR	5	760	850

Tab. 3: Spektrální pásma RapidEye (zpracováno dle Planet, 2018)



Obr. 13: Družice RapidEye (Geoimage, 2019)

Vybráno bylo 5 bezoblačných termínů v průběhu vegetační sezóny 2016 a 2018. Jejich seznam uvádí Tab. 4.

Termín snímání
8.8.2016
25.8.2016
27.8.2018
7.9.2016
12.9.2018

Tab. 4: Bezoblačné termíny dat RapidEye využité pro klasifikaci

4.1.3 Hyperspektrální dat Apex

Senzor APEX (Airborne Prism Experiment) je výsledkem belgicko-švýcarského projektu, který byl zahájen v roce 1991 pod záštitou Evropské kosmické agentury (ESA). První prototyp senzoru byl sestaven v roce 2007 a od roku 2011 slouží komerčním a vědeckým účelům. Hyperspektrální data APEX použitá v této diplomové práci disponují 288 spektrálními pásmy v rozmezí vlnových délek 413,4–2447,8 nm a nabízejí prostorové rozlišení 2,65 m (APEX, 200?). Snímek byl pořízen 10. září 2012.

Data APEX použitá v diplomové práci byla atmosféricky i geometricky korigována. Geometrická korekce proběhla s využitím modulu C++ na základě přímého georeferencování. Atmosférická korekce byla vytvořena pomocí CDPC (Central Data Processing Center) s radiativním transferem MODTRAN4 a bere v úvahu centrální vlnové délky pro každý pixel (Apex, 2012).

4.1.4 Terénní data

Ke sběru terénních dat docházelo v průběhu let 2014, 2015, 2016 a 2017 pomocí GPS přístroje Trimble Geoexplorer 3000 Geo XT. Zaměřeno bylo celkem 134 polygonů, z čehož 69 polygonů připadá na kategorii smilka tuhá, 30 třtina chloupkatá a 35 bezkoleneček modrý.

4.1.5 Ostatní datové zdroje

K účelu vizuální interpretace zájmového území byla využita webová mapová služba ortofoto ČR. Jako vstup do klasifikace Random Forest posloužil digitální model terénu zájmového území, který byl poskytnut Katedrou aplikované geoinformatiky a kartografie. Pořízen byl z dat leteckého laserového skenování (bodové mračno o hustotě 5 bodů/m²), která byla nasnímána v roce 2012. Pro mapové výstupy byla využita volně dostupná data z databáze ArČR500 a Dibavod.

4.2 Předzpracování dat

Pro zpracování dat bylo využito programů Envi 5.3, ArcGis PRO, R a Excel.

4.2.1 Atmosférické korekce

Pro ověření vhodnosti užití produktu Surface Reflectance (SR) dat Planet Scope byla v softwaru Envi 5.3. vypočítána průměrná odrazivost z pásem Blue, Green, Red a NIR pro jednotlivé termíny na základě vybraných polygonů, u nichž se předpokládá, že by měly být spektrálně stabilní. Vybrán byl polygon vodní plochy na severovýchodě území a polygon zachycující střechu Luční boudy. U těchto povrchů nejsou očekávány výrazné odchylky v hodnotách odrazivosti, a mohou tak být srovnávány napříč termíny. Porovnány byly hodnoty odrazivosti pro termíny s atmosférickou korekcí QUAC a pro termíny, pro které byla využita data PlanetScope Surface Reflectance. Aby mohla být porovnána i data s odlišnou metodou provedení atmosférické korekce a bez provedení korekce v rámci jednoho termínu, průměrné hodnoty odrazivosti byly vypočítány také pro data PlanetScope SR, QUAC a snímky bez atmosférické korekce z termínu 7.8.2018. Kromě hodnot pro vodní plochy a střechu byly zjištěny také hodnoty odrazivosti pro sledované travní kategorie.

4.2.2 Klasifikační maska

Aby klasifikace probíhala pouze pro travní kategorie vegetace, musela být vytvořena klasifikační maska (viz Obr. 14). Nejprve byly odmaskovány nevegetační kategorie (vodní plochy, kamenná moře, antropogenní plochy). Pro vybraný snímek PlanetScope byl vypočítán NDVI. Na základě vizuální interpretace nad ortofotem byla stanovena prahová hodnota, podle které byly pixely rozděleny do 2 tříd. Ty pixely, které měly hodnotu indexu nižší než 0,55, byly odstraněny, a ty, jejichž hodnota byla vyšší než 0,55, zachovány. Nad výsledkem tohoto procesu byla provedena neřízená klasifikace ISO

CLUSTER v ArcGIS Pro. Na základě jejího výstupu byly všechny třídy kromě tří, které odpovídaly klasifikovaným travním kategoriím, odmaskovány.



Obr. 14: Klasifikační maska

4.3 Analýza dat

4.3.1 Analýza spektrálních příznaků sledovaných kategorií

K nalezení vhodných termínů a spektrálních pásem pro klasifikaci byly zjištěny průměrné odrazivosti trénovacích ploch tří analyzovaných kategorií v jednotlivých pásmech. Všechny kategorie se vyznačují velmi podobným spektrálním signálem. Spektrální křivky byly analyzovány pro data uvedená v Tab. 2.

Trénovací plochy pro analýzu spektrálních příznaků

Analýza spektrálních příznaků proběhla nejprve na základě trénovacích ploch, ve kterých daná kategorie může obsahovat v malém množství příměs kategorie jiné (trénovací data zahrnovala jednak polygony bez příměsi jiných druhů a částečně také polygony s malým množstvím příměsi). Následně byly spektrální křivky vypočteny také pro ty plochy, které obsahují pouze třídy bez příměsi. Bylo zjištěno, že příměs významně neovlivňuje hodnoty odrazivosti, a proto byla pro klasifikaci využita tato početnější skupina dat obsahující i smíšené plochy.

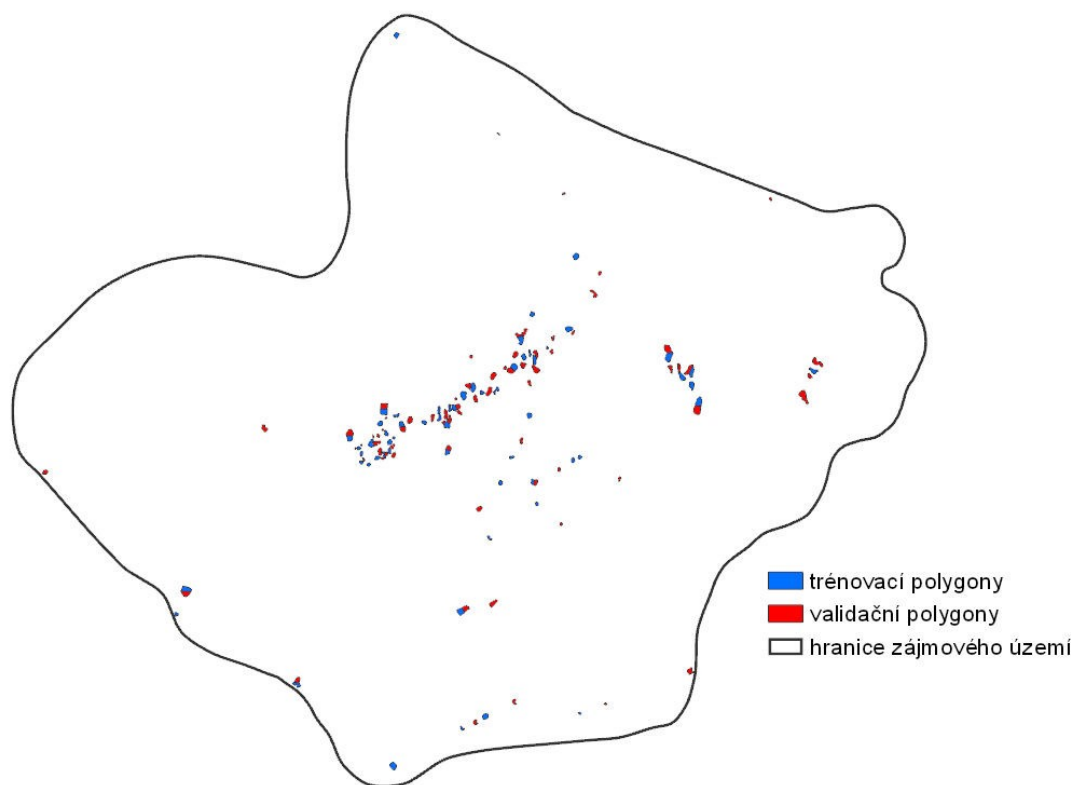
Informace o počtu trénovacích ploch a pixelů uvádí Tab. 5.

	Počet pixelů	Počet ploch
Smilka tuhá	2267	69
Třtina chloupkatá	742	30
Bezkolnec modrý	868	35

Tab. 5: Plochy pro analýzu spektrálních příznaků

4.3.2 Klasifikace

Klasifikována byla v první řadě data PlanetScope, pro porovnání výsledků potom také data RapidEye a hyperspektrální snímek Apex. Využito bylo jednak řízené pixelové klasifikace MLC a SVM a objektové SVM v ENVI 5.3. Dále pak klasifikace metodou Random Forest, která proběhla v softwaru R 3.5.3. Klasifikovány byly 3 kategorie vegetačního pokryvu, jejichž přehled je uveden v Tab. 5. Plochy využitě pro analýzu spektrálních charakteristik byly rozděleny na trénovací a validační tak, aby validačních byla více než polovina a aby byly rovnoměrně rozmístěny v zájmovém území (Obr. 15). Jejich počty uvádí Tab. 6.



Obr. 15: Rozmístění trénovacích a validačních ploch pro klasifikaci

	Počet pixelů		Počet ploch	
	Trénovací	Validační	Trénovací	Validační
Smilka tuhá	1059	1208	31	38
Třtina chloupkatá	381	371	14	16
Bezkoleneč modrý	419	449	17	18

Tab. 6: Trénovací a validační plochy pro klasifikaci (pro prostorové rozlišení dat PlanetScope)

Klasifikace proběhla jednak pro jednotlivé termíny daného typu dat, ale také pro multitemporální kompozity. Proces klasifikace byl rozdělen do dvou základních fází.

Pro zjištění, zda má odlišná metoda provedení atmosférické korekce vliv na klasifikační přesnost, byla v první řadě v rámci multitemporálního kompozitu dat PlanetScope testována data atmosféricky korigovaná dvěma různými způsoby, jejichž přehled uvádí Tab. 7. Tyto kompozity obsahovaly všechna spektrální pásma daného typu dat ze všech využitých termínů snímání a byly klasifikovány metodou MLC. Kompozit 1 obsahuje 10 termínů (40 pásem), které byly korigovány společností PlanetScope (Surface Reflectance product). Vyřazeny byly termíny 21.6.2017 a 28.8.2016, pro které tento produkt nebyl dostupný. Kompozit 2 je složen ze všech 12 termínů (48 pásem), které byly korigovány pomocí modulu QUAC. Kompozit 3 potom obsahuje 10 termínů (40 pásem) s korekcí PlanetScope SR a 2 termíny (21.6.2017 a 28.8.2016) korigované pomocí QUAC. V případě dat Rapid Eye kompozity obsahovaly všechny termíny (25 pásem), které uvádí Tab. 4.

Klasifikace MLC z dat korigovaných pomocí QUAC byla provedena také pro termín 7.8.2018. Tento termín byl vybrán z důvodu nejvyšší klasifikační přesnosti v případě využití dat korigovaných společností Planet (viz kapitola 5.3.1.1.). Klasifikační přesnosti výše uvedených dat byly následně porovnány.

	Typ atmosférické korekce	Počet termínů
Kompozit 1	PlanetScope SR	10
Kompozit 2	QUAC	12
Kompozit 3	PlanetScope SR+QUAC	12

Tab. 7: Multitemporální kompozity dat PlanetScope s odlišnou metodou provedení atmosférické korekce

Pozn. Konkrétní termíny jsou uvedeny v Tab. 2

V druhé fázi procesu byl klasifikátor RF a SVM klasifikován pouze ten multitemporální kompozit PlanetScope, který dosáhl v první fázi nejlepšího výsledku. Z důvodu odstranění korelace mezi pásmy byla pro multitemporální kompozity PlanetScope, RapidEye a jednotlivý termín APEX provedena PCA transformace, v případě dat APEX také MNF transformace. Na základě informací o vhodnosti užití

transformovaných pásem získaných z Kupková et al. (2017), byly testovány kombinace 10 pásem PCA v případě dat PlanetScope a Rapid Eye (Tab. 8), pro data Apex potom 10 a 40 pásem PCA a MNF (Tab. 9).

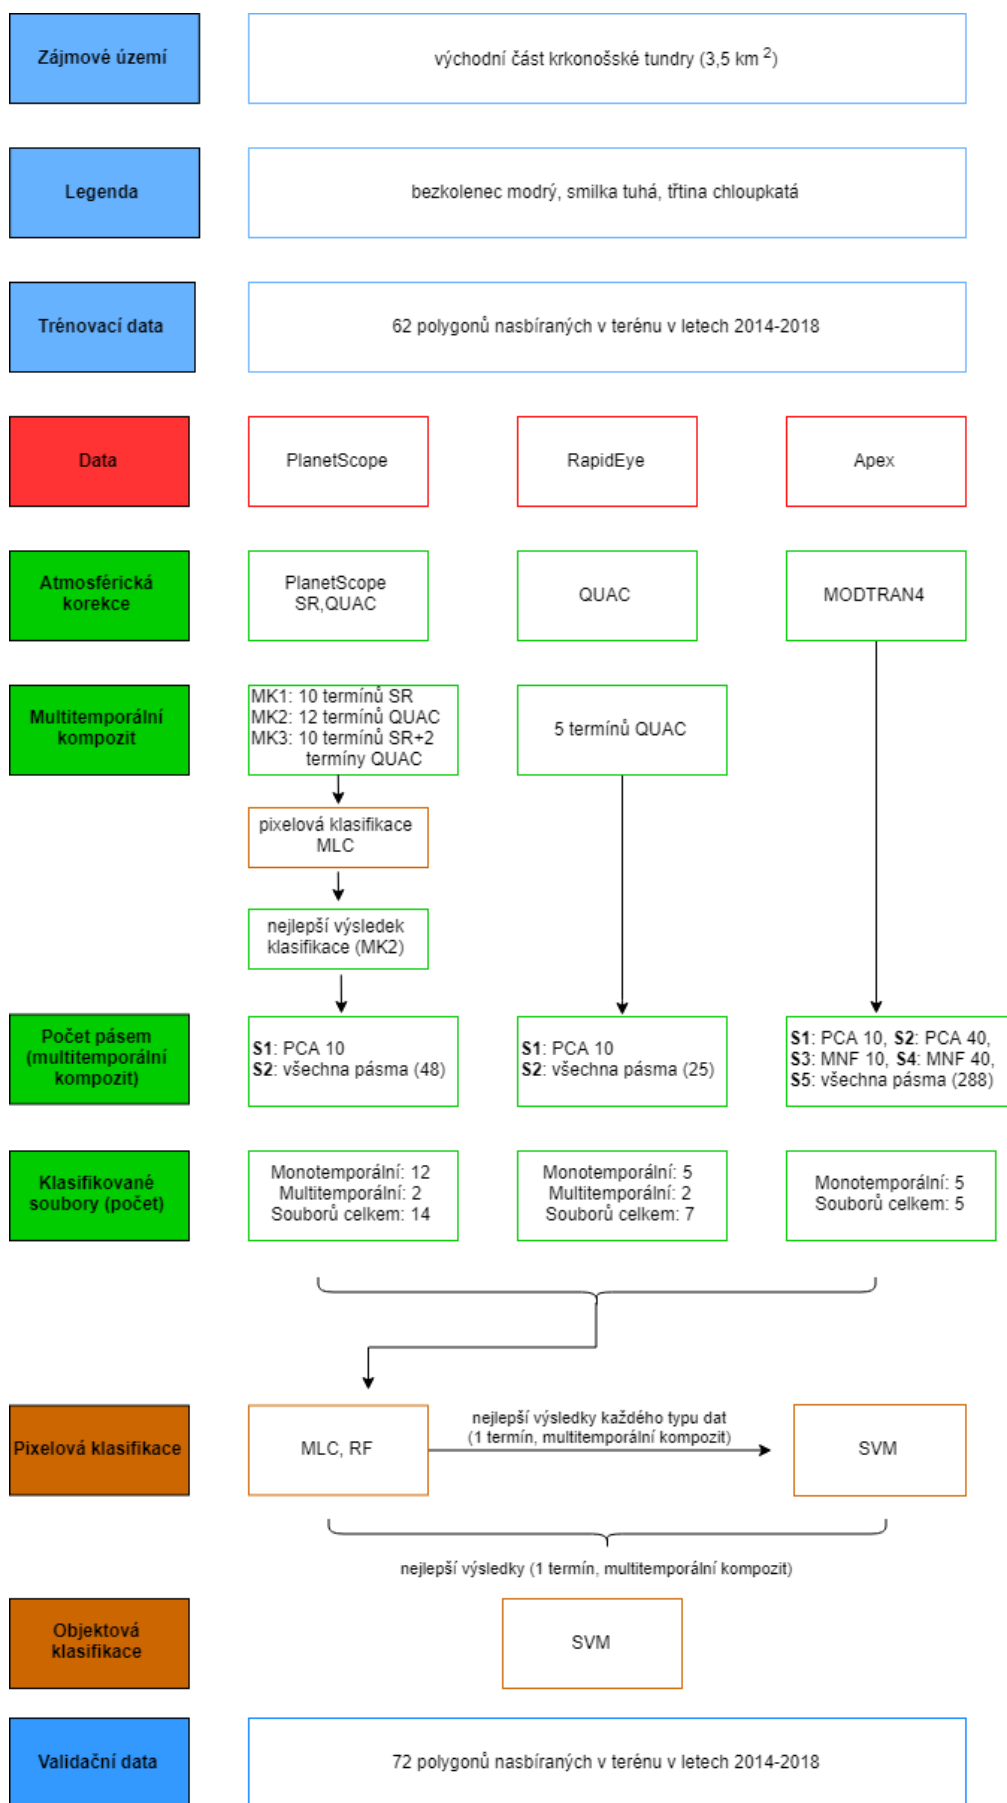
	Počet spektrálních pásem
PlanetScope 1	10 PCA
PlanetScope 2	48
RapidEye 1	10 PCA
RapidEye 2	25

Tab. 8: Multitemporální kompozity dat PlanetScope a RapidEye

	Počet spektrálních pásem
APEX 1	10 PCA
APEX 2	40 PCA
APEX 4	10 MNF
APEX 5	40 MNF
APEX 6	288

Tab. 9: Testované kombinace spektrálních pásem dat APEX

Klasifikace metodou MLC a RF byla provedena pro všechny termíny a multitemporální kompozity dat PlanetScope. Klasifikace SVM byla využita pouze pro data, která dosáhla klasifikací MLC a RF nejlepších výsledků. Objektová klasifikace proběhla pro multitemporální kompozit a jednu scénu, která byla pixelovým přístupem klasifikována s nejvyšší přesností. Z výsledků klasifikace MLC byly vypočítány také rozlohy pro jednotlivé klasifikované traviny. Pracovní postup je uveden na Obr. 16.



Obr. 16: Pracovní postup (pozn. MK – multitemporální kompozit, S – soubor)

Klasifikace metodami MLC a SVM

Envi 5.3. umožňuje pro klasifikátor MLC volit pouze parametr *“Probability Treshold”*, který byl nastaven jako *“None”*. V případě klasifikace SVM bylo testovány různé parametry nastavení klasifikátoru. Nejlepších výsledků bylo dosaženo následujícím nastavením: *“Kernel Type”*: *RBF*, *“Gamma in Kernel Function”*: *převrácená hodnota z počtu vstupních spektrálních pásem*, *“Penalty Parameter”*: *100*, parametry *“Probability Treshold”* a *“Pyramid Levels”* nebyly využity. Aplikací stejných parametrů v rámci objektové klasifikace bylo dosaženo nejlepších výsledků také v Kupková et al. (2017).

Klasifikace metodou Random Forest

Za účelem zvýšení přesnosti klasifikace vybraných vegetačních druhů byly testovány různé kombinace proměnných vstupujících do klasifikačního procesu, které uvádí Tab. 10.

Nejprve byl do softwaru RStudio funkcí *“brick”* načten vstupní satelitní snímek. Následně byly pro všechna pásma vstupního snímku vypočteny texturální charakteristiky (mean, variance, homogeneity, contrast, dissimilarity, entropy, second moment) z Gray-Level-Co-Occurrence Matrix pomocí funkce *“glcm”*. Testovány byly různé velikosti filtrovacího okna a na základě nejlepších výsledků jeho velikost stanovena na hodnotu 3x3. Funkcí *“brick”* byl načten digitální model terénu a funkcí *“resample”* převzorkován na prostorové rozlišení satelitního snímku. Využita byla metoda bilineární interpolace, která je podle USGS (2019) vhodnější pro výšková terénní data než metoda Nearest Neighbor. Z digitálního modelu terénu byl následně pomocí funkce *“terrain”* vypočítán sklon a orientace svahu. Podle vzorce:

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

byl také vypočítán NDVI. Všechny vypočítané proměnné byly funkcí *“crop”* oříznuty podle vstupního snímku a následně funkcí *“stack”* spojeny do jednoho datasetu. Aby klasifikace probíhala pouze pro vybrané travní kategorie, byla na tento soubor aplikována vytvořená vegetační maska funkcí *“mask”*. K natrénování modelu bylo využito trénovacích dat naměřených pomocí GPS (viz kapitola 4.1.4). Trénovací polygony byly nahrány jako .shp a pomocí funkce *“extract”* z datasetu vstupních rastrů extrahovány jejich hodnoty a uloženy do souboru s trénovacími daty, který sloužil k natrénování klasifikátoru. Každému trénovacímu pixelu tak byla kromě hodnoty jednotlivých rastrů vstupujících do klasifikace přiřazena i informace o třídě. Ze souboru s trénovacími daty byly vybrány ty proměnné, které budou sloužit jako vstup do klasifikace. Funkcí *“RandomForest”* byl natrénován model. Testovány byly rozdílné kombinace vstupních proměnných. Protože výpočet texturálních proměnných probíhá zvlášť pro každé spektrální pásmo, jejich počet, a tedy i celkový počet

proměnných, je závislý na počtu spektrálních pásem vybraného typu dat. (Tab. 11). Pro zjištění, které kategorie proměnných jsou pro daný typ klasifikačního procesu nevhodnější, byly rozděleny do 3 skupin (texturální, spektrální a topografické) a klasifikovány zvlášť.

	Proměnné
spektrální	B1
	B2
	B3
	B4
	NDVI
topografické	sklon svahu
	orientace svahu
	nadmořská výška z DTM
texturální	mean
	variance
	homogeneity
	contrast
	dissimilarity
	entropy
	second moment

Tab. 10: Proměnné vstupující do klasifikace RF

Pozn. Počet spektrálních proměnných se liší v závislosti na počtu spektrálních pásem vybraného typu dat. V tabulce jsou uvedeny údaje pro data PlanetScope.

	Vstupní data	Počet proměnných
Jednotlivé termíny	PlanetScope	36
	RapidEye	44
	Apex	2307, 323 (10 PCA/MNF), 83 (10 PCA/MNF)
Multitemporální kompozit	PlanetScope	388, 84 (PCA 10)
	RapidEye	204, 84 (PCA 10)

Tab. 11: Počty proměnných vstupujících do klasifikace RF pro různé typy dat

Na základě studované literatury (viz kapitola 2.2.1) byl počet vstupních proměnných, ze kterých je náhodně vybíráno v každém uzlu ($mtry$), stanoven podle vzorce:

$$mtry = \sqrt{p}$$

Kde p odpovídá počtu proměnných vstupujících do klasifikace. Testovány byly také různé počty stromů (n tree) a jejich počet na základě výsledků nastaven na hodnotu 1000. Klasifikace proběhla funkcí "predict". Pomocí funkce "importance" a volbou typu výpočtu "Mean Decrease Accuracy" byly

zjištěny důležitosti jednotlivých proměnných v klasifikačním modelu. Výsledek tohoto procesu udává, o kolik se sníží přesnost klasifikačního modelu, pokud je daná proměnná z klasifikačního procesu vyřazena. Čím vyšší hodnota je, tím větší důležitosti v klasifikačním modelu proměnná nabývá (Rdocumentation, 2019). Jak uvádí Kuhn (2008), znalost důležitosti proměnných pomáhá k výběru optimálního počtu vstupních proměnných a s tím spojené dosažení vyšší klasifikační přesnosti.

Klasifikovaný snímek byl posléze exportován do formátu .tiff. V softwaru ENVI 5.3. byla vypočítána chybová matice a vyhodnoceny uživatelské a zpracovatelské přesnosti klasifikace.

Objektová klasifikace

Objektová klasifikace byla provedena v softwaru ENVI 5.3. s využitím nástroje Example Based Feature Extraction Classification. Na základě znalosti charakteru území (ostré přechody mezi jednotlivými objekty zájmu a velké množství malých objektů) a na základě doporučení získaného z Harris Geospatial Solutions (2019) byl vybrán byl segmentační algoritmus Edge a spojovací algoritmus Full Lambda Schedule. Testovány byly různé parametry nastavení a využita byla kombinace všech čtyř spektrálních pásem. V průběhu testování se vzhledem k prostorovému rozlišení dat ukázalo jako nejvhodnější nastavení parametru Scale Level na hodnotu 15 a Merge Level na hodnotu 75. Data byla klasifikována pomocí všech dostupných spektrálních, texturálních a prostorových příznaků s využitím klasifikátoru SVM.

Hodnocení přesnosti klasifikace

Přesnost klasifikace byla vypočítána na základě validačních dat pomocí funkce Confusion Matrix Using Ground Truth ROIs v Envi 5.3. Vygenerována byla chybová matice a z ní vypočítána celková přesnost, kappa koeficient, zpracovatelská a uživatelská přesnost.

5 Výsledky

5.1 Atmosférické korekce

Výsledky analýzy spektrálně stálých povrchů (vodní plocha a střecha Luční boudy) ukázaly, že odchylky hodnot odrazivosti jsou patrné i v případě využití dat se stejnou metodou provedení atmosférické korekce. Při užití metody QUAC se ale hodnoty liší výrazněji. U termínů 21.6.2017 a 28.8.2016 lze pozorovat mírně vyšší hodnoty v případě odrazivosti střechy, v případě odrazivosti pixelů reprezentujících vodní plochy se naopak hodnoty jednoznačně řadí k nejnižším (viz Tab. 12).

Pokud se týká odrazivosti 12 termínů korigovaných QUAC, rozdíly hodnot jsou mezi jednotlivými termíny v podobném poměru jako v případě korekce PlanetScope SR. Hodnoty jsou uvedeny v Tab. 13.

Termíny	Odrazivost	
	Vodní plocha	Střecha
7.6.2018	423,3	1448,3
21.6.2017	219,5	1735,0
7.7.2018	306,5	1520,8
22.7.2018	701,8	1581,0
30.7.2017	252,5	1339,5
7.8.2018	406,5	1524,8
20.8.2018	429,8	1294,5
27.8.2018	321,0	1390,0
28.8.2016	201,8	1879,8
5.9.2017	646,8	1646,5
8.9.2016	169,8	1199,5
10.9.2018	250,0	1479,3

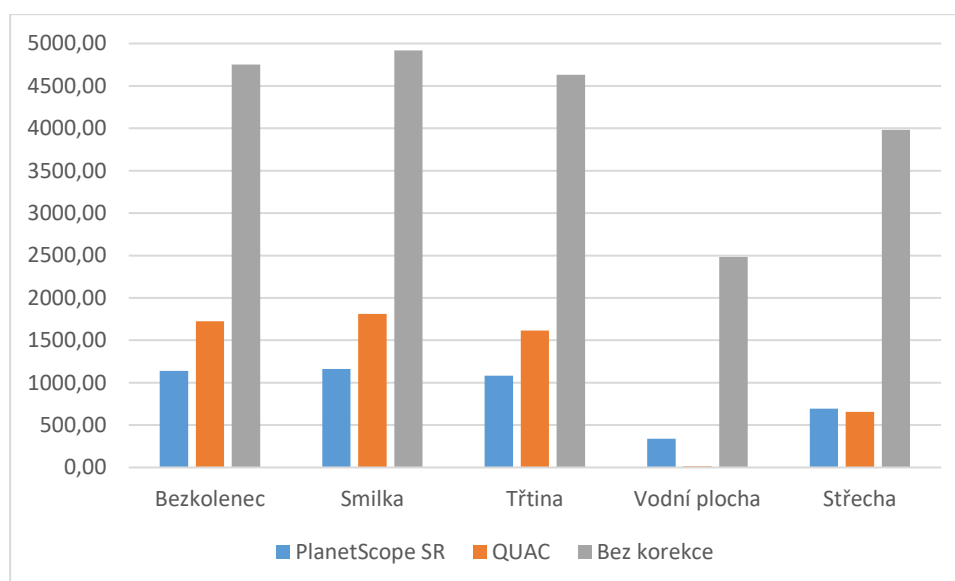
Tab. 12: Průměrné odrazivosti odlišných povrchů napříč termíny dat PlanetScope

Pozn. Termíny, pro které je provedena atmosférická korekce QUAC, jsou barevně zvýrazněny

Termíny	Odrazivost	
	Vodní plocha	Střecha
7.6.2018	151,57	1071,43
21.6.2017	93,22	1181,18
7.7.2018	178,31	868,68
22.7.2018	92,03	773,50
30.7.2017	35,63	649,12
7.8.2018	12,34	654,60
20.8.2018	81,51	830,63
27.8.2018	115,08	1009,15
28.8.2016	64,50	1371,60
5.9.2017	199,97	983,30
8.9.2016	9,40	836,30
10.9.2018	134,29	959,75

Tab. 13: Průměrné odrazivosti odlišných povrchů napříč termíny dat PlanetScope s atmosférickou korekcí QUAC

Při porovnání dat z jednoho termínu snímání zůstává rozdíl mezi hodnotami odrazivosti v podobném poměru. Data, na kterých nebyla provedena atmosférická korekce, mají podle očekávání, v porovnání s korigovanými, velmi vysoké hodnoty.



Obr. 17: Průměrné odrazivosti odlišných povrchů termínu 7.8.2018 z dat korigovaných PlanetScope SR, korigovaných modelem QUAC a atmosféricky nekorigovaných

5.2 Analýza spektrálních příznaků sledovaných kategorií


Jak je zřejmé z Příloha 7, křivky průměrné odrazivosti sledovaných druhů charakterizuje nízká odrazivost ve viditelné části spektra. Křivky pro všechny vegetační kategorie napříč termíny mají

podobný průběh. V pásmu 1 (Blue), v rozsahu vlnových délek 455-515 nm, je odrazivost velmi nízká a rozdíly mezi kategoriemi zanedbatelné, proto k odlišení vegetace není příliš vhodná. Zatímco v pásmu Green (2) a Red (3) kategorie vykazují pouze mírné rozdíly, v infračervené části spektra na vlnových délkách od 780 nm odrazivost výrazně narůstá. V tomto pásmu jsou také rozdíly mezi jednotlivými kategoriemi nejzřetelnější, a proto je nejvhodnější pro rozlišení vybraných travin.

Z Obr. 18 je zřejmé, že nejvyšší odrazivost v NIR napříč termíny vykazuje bezkolence modrý. Nejnížší naopak smilka tuhá, u které se ale odrazivost zvyšuje začátkem srpna. Nízká odrazivost třtiny na konci sezóny pravděpodobně souvisí s jejím výrazným přechodem ze zelené do červeno-fialové barvy. Koncem srpna a začátkem září lze u hodnot odrazivosti sledovat spíše sestupnou tendenci, která souvisí s usycháním a s tím spojenou změnu barvy listů u všech kategorií.

Netypický průběh křivek spektrální odrazivosti, tedy poměrně vysokou odrazivost v červnu a začátkem července a oproti očekávání nízkou odrazivost v pozdních červencových a raně srpnových termínech, lze do určité míry vysvětlit právě netradičním průběhem sezóny 2018. K zelenému zbarvení listů vybraných travin došlo již počátkem června, zatímco v srpnu (všechny analyzované snímky z tohoto měsíce jsou z roku 2018) již u listů začaly barevné změny, čemuž odpovídá i nízká odrazivost. Průběh zářijových termínů, které byly pořízeny v letech 2016, resp. 2017, je již pro toto období poměrně typický.

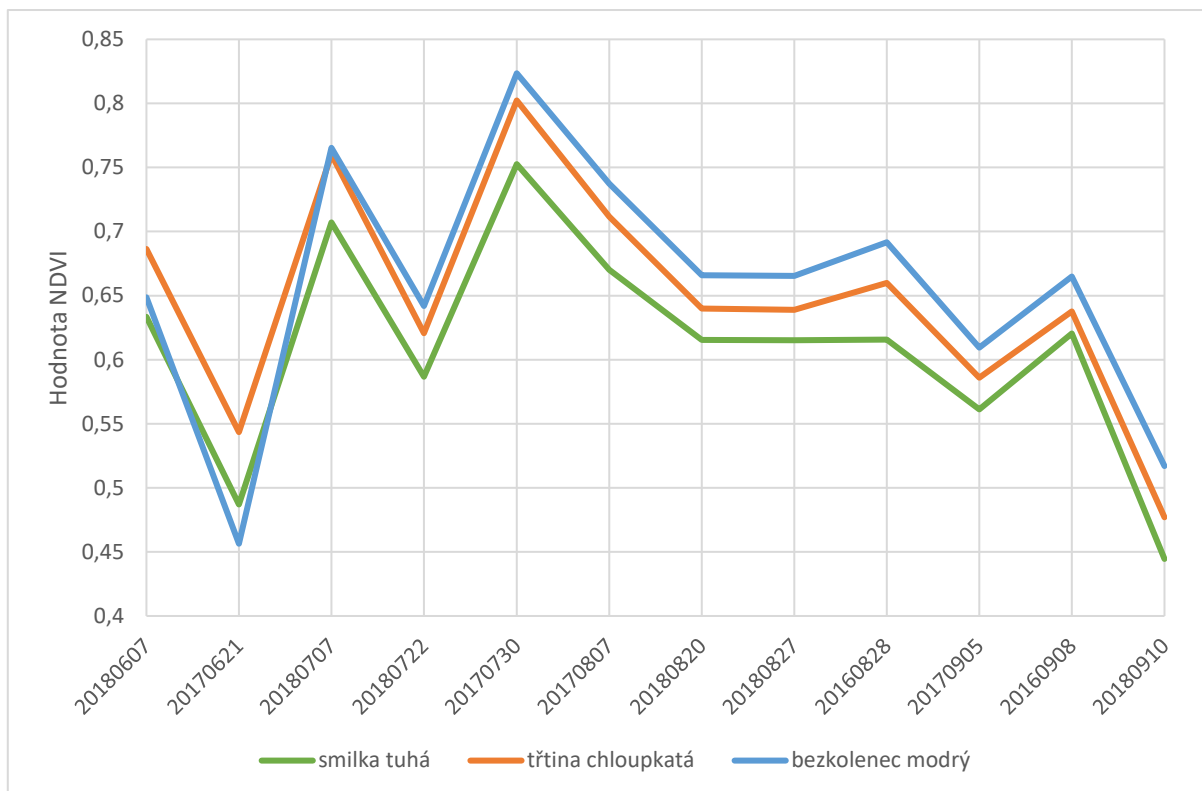
Jako nejlepší termíny pro rozlišení jednotlivých kategorií na základě spektrálních odrazivostí v jednotlivých pásmech byly vyhodnoceny 30.7.2017 a 28.8.2016. Konkrétně pro odlišení třtiny a smilky lze označit jako nejvhodnější termín 30.7.2017. V případě odlišení bezkolence se jeví jako vhodné termíny na přelomu srpna a září.



Obr. 18: Průměrná odrazivost trénovacích ploch v jednotlivých termínech v NIR

Jako nejlepší termíny pro rozlišení jednotlivých kategorií na základě průměrné hodnoty NDVI byly vyhodnoceny 21.6.2018 a 28.8.2016 (Obr. 19). Pro odlišení třtiny od smilky a bezkolence od třtiny je nejvhodnější 21.6.2017 a pro rozlišení smilky od bezkolence nejvhodnější 28.8.2016.

Křivka časové řady NDVI odpovídá předpokládanému sezónnímu chování sledovaných vegetačních druhů. Maximálních hodnot je v případě všech kategorií dosaženo na konci července, po tomto termínu hodnota indexu klesá a jeho minimum nastává v září. Tento průběh značí stárnutí vegetace (senescenci), ztrátu chlorofylu a s tím spojený proces usychání. Vysoké hodnoty v termínu 7.6.2018 a naopak nízké v termínu 22.7.2018 lze vysvětlit velmi teplým a suchým průběhem sezóny 2018 (viz kapitola 3.2). Sledovaná travní vegetace začala kvést již v červnu (nadprůměrně vysoké teploty v květnu) a k usychání docházelo již na konci července. Nejvyšších průměrných hodnot NDVI dosahuje po většinu sezóny bezkoleneček modrý, nejnižších potom smilka tuhá.



Obr. 19: Průměrné hodnoty NDVI ve sledovaných termínech

5.3 Klasifikace

5.3.1 Porovnání atmosféricky korigovaných dat PlanetScope

Nevyšší přesnosti (80,67 %) bylo metodou MLC dosaženo pro multitemporální kompozit, který kombinuje všechny dostupné termíny korigované pomocí QUAC (Kompozit 2). Co se týče klasifikace jednoho termínu, data QUAC (75,54 %) a SR (76,06 %) dosáhla podobných přesností (Tab. 14).

	Celková přesnost (%)	Kappa
Kompozit 1	78,40	0,59
Kompozit 2	80,67	0,64
Kompozit 3	78,29	0,60
QUAC, 7.8.2018	75,54	0,49

Tab. 14: Porovnání klasifikačních přesností pro data s odlišnou metodou provedení atmosférické korekce

5.3.1.1 Maximum Likelihood

V případě dat PlanetScope nejvyšší přesnosti klasifikace dosáhl termín 7.8.2018 (71,04 %), celkově potom vyšla klasifikace nejpřesněji pro kompozit PlanetScope 2, který obsahuje všechna pásma (71,45 %). Přesnosti klasifikace MLC jednotlivých termínů uvádí Tab. 15.

Termíny	Celková přesnost (%)	Kappa koeficient
7.6.2018	45,63	0,1535
21.6.2017	54,35	0,2623
7.7.2018	62,57	0,3602
22.7.2018	63,05	0,3779
30.7.2017	64,52	0,4347
7.8.2018	71,04	0,5004
20.8.2018	58,19	0,3375
27.8.2018	62,72	0,3927
28.8.2016	57,37	0,3205
5.9.2017	51,36	0,2452
8.9.2016	54,37	0,2946
10.9.2018	55,99	0,2815
Multitemporální kompozit	71,45	0,4424

Tab. 15: Celkové přesnosti klasifikace dat PlanetScope klasifikátorem MLC pro jednotlivé termíny a multitemporální kompozit

Nejvyšší zpracovatelské přesnosti bylo dosaženo pro kategorii smilka tuhá v případě klasifikace multitemporálního kompozitu, bezkolenec modrý dosáhl nejvyšší přesnosti v termínu 30.7.2017 a třtina byla nej přesněji klasifikována 8.9.2016. Uživatelská přesnost byla nejvyšší pro bezkolenec modrý v případě klasifikace multitemporálního kompozitu, pro smilku 30.7.2017 a třtinu v termínu 5.9.2017 (Tab. 16).

Nejvyšší průměrné zpracovatelské přesnosti dosáhla třtina chloupkatá (72,3 %), nevyšší uživatelské přesnosti potom smilka tuhá (76,83 %).

	Zpracovatelská přesnost (%)			Uživatelská přesnost (%)		
	Bezkolenec	Smilka	Třtina	Bezkolenec	Smilka	Třtina
7.6.2018	20,81	44,01	80,32	47,66	63,64	34,24
21.6.2017	39,86	55,3	67,88	41,77	71,44	38,59
7.7.2018	31,08	71,05	72,58	48,08	77,53	42,86
22.7.2018	39,32	69,34	70,86	42,72	79,12	47,58
30.7.2017	55,91	63,91	76,3	56,16	86,84	41,56
7.8.2018	40,23	80,22	78,02	65,8	84,84	47,78
20.8.2018	36,73	60,02	77,84	60,67	82,14	33,18
27.8.2018	32,21	61,9	72,16	41,57	82,57	35,49
28.8.2016	32,21	61,9	72,16	41,57	82,57	35,49
9.5.2017	22,72	52,36	82,57	22,72	52,36	82,57
8.9.2016	25,39	55,83	83,51	36,69	83,44	34,83
10.9.2018	23,37	62,18	74,54	36,88	76,48	36,93
Multitemporální kompozit	49,22	91,97	31,54	62,43	75,78	56,25

Tab. 16: Zpracovatelská a uživatelská přesnost klasifikace dat PlanetScope klasifikátorem MLC pro jednotlivé termíny a multitemporální kompozit

Z Tab. 17 je zřejmé, že v případě dat RapidEye nejlepší celkové přesnosti dosáhl kompozit RapidEye 2, který obsahuje všechna pásma. Data APEX byla s nejvyšší celkovou přesností klasifikována v případě výběru 40 pásem PCA (61,39 %).

	Celková přesnost (%)		
	PlanetScope	RapidEye	APEX
Multitemporální kompozit	71,45	73,19	x
Jednotlivý termín	71,04	66,07	61,39

Tab. 17: Porovnání přesností klasifikace MLC pro jednotlivé termíny a multitemporální kompozit dat PlanetScope, RapidEye a APEX

Co se týče rozlohy jednotlivých travin, největší podíl na rozloze klasifikovaného území ve všech sledovaných termínech zaujímá smilka tuhá. Při porovnání pozdně srpnových termínů let 2016 a 2018 (28.8.2016 a 27.2018) je zaznamenán mírný nárůst procentuálního zastoupení této kategorie (38,59 % oproti 41,57 %). Opačný trend, tedy pokles rozlohy, lze pozorovat u třtiny chloupkaté (29,21 % oproti 24,99 %). V případě bezkolence modrého jsou zaznamenány podobné hodnoty (32,2 % oproti 33,34 %)- viz Tab. 18.

Rok	Termín	Bezkolence modrý (%)	Smilka tuhá (%)	Třtina chloupkatá (%)
2016	28.8.2016	32,20	38,59	29,21
	8.9.2016	23,75	44,58	31,67
2017	21.6.2017	24,79	57,84	17,37
	30.7.2017	36,22	44,28	19,49
	5.9.2017	22,13	39,03	38,84
2018	7.6.2018	31,51	39,92	28,57
	7.7.2018	30,71	48,81	20,48
	22.7.2018	31,02	47,75	21,22
	7.8.2018	30,07	42,85	27,08
	20.8.2018	25,26	43,10	31,64
	27.8.2018	33,44	41,57	24,99
	10.9.2018	23,75	44,58	31,67

Tab. 18: Rozlohy sledovaných travin v klasifikovaných termínech let 2016, 2017 a 2018 vypočítané na základě snímků klasifikovaných MLC

5.3.1.2 Support Vector Machine

Pro data PlanetScope i RapidEye dosáhl nejvyšší celkové přesnosti multitemporální kompozit (PlanetScope - 69,62 %, RapidEye - 72,16 %). Data APEX byla s nejvyšší celkovou přesností klasifikována v případě výběru 40 pásem PCA (75,20 %). Přesnosti klasifikace shrnuje Tab. 19.

	Celková přesnost (%)		
	PlanetScope	RapidEye	APEX
Multitemporální kompozit	69,62	72,16	x
Jednotlivý termín	64,31	71,16	75,20

Tab. 19: Porovnání přesností klasifikace SVM pro jednotlivé termíny a multitemporální kompozit dat PlanetScope, RapidEye a APEX

5.3.1.3 RandomForest

Co se týká dat PlanetScope, nejvyšší přesnosti bylo klasifikátorem RF dosaženo pro kompozit všech pásem (80,67 %). Z jednotlivých termínů byl nejpřesněji klasifikován termín 7.8.2018 (76,06 %). Nejvyšší zpracovatelské přesnosti v případě multitemporálního kompozitu dosáhla smilka tuhá, uživatelské potom třtina chloupkatá (Tab. 20). V případě jednoho termínu dosáhla nejvyšší zpracovatelské i uživatelské přesnosti smilka tuhá. S nejnižší zpracovatelskou i uživatelskou přesností byl v obou případech hodnocen bezkolenec modrý.

	Zpracovatelská přesnost (%)			Uživatelská přesnost (%)		
	Bezkolenec	Smilka	Třtina	Bezkolenec	Smilka	Třtina
7.8.2018	55,81	86,13	69,44	66,17	80,05	72,75
Multitemporální kompozit	59,24	92,05	69,54	73,28	81,70	84,87

Tab. 20: Zpracovatelská a uživatelská přesnost klasifikace dat PlanetScope metodou RF pro nejlépe hodnocený termín a multitemporální kompozit

Z chybové matice klasifikace multitemporálního kompozitu (Tab. 21) je zřejmé že, nejčastěji dochází k záměně mezi bezkolencem a smilkou.

	1	2	3	Total
1	221	61	72	354
2	173	1111	182	1466
3	55	36	117	208
Total	449	1208	371	2028

Tab. 21: Chybová matice klasifikace Random Forest pro Kompozit 2

Pozn.: (1) bezkolenec modrý, (2) smilka tuhá, (3) třtina chloupkatá

V případě dat RapidEye byl nejpřesněji klasifikován termín 27.8.2018 (73,77 %), multitemporální kompozit tohoto typu dat dosáhl nižší přesnosti. (Tab. 22). V rámci dat APEX bylo s nejvyšší přesností (75,92 %) klasifikováno 40 pásem PCA.

	Celková přesnost (%)		
	PlanetScope	RapidEye	APEX
Multitemporální kompozit	80,67	74,75	x
Jednotlivý termín*	76,06	73,77	75,92

Tab. 22: Celková přesnost klasifikace RF klasifikátorem RF pro nejlépe hodnocený termín a multitemporální kompozit

Pokud se týká vlivu jednotlivých typů proměnných na přesnost klasifikace, výsledky pro nejlépe klasifikovaný samostatný termín (7.8.2018) ukázaly, že nejvyšší klasifikační přesnosti dosáhly texturální proměnné (71,98 %), avšak spektrální proměnné dosáhly pouze mírně nižší přesnosti. Nejnižší přesnost (67,7 %) byla zjištěna pro topografické proměnné (Tab. 23).

	Texturální	Spektrální	Topografické
Celková přesnost (%)	71,98	71,23	67,7
Kappa	0,49	0,48	0,39

Tab. 23: Klasifikační přesnosti pro jednotlivé kategorie proměnných pro termín 7.8.2018

V případě využití všech proměnných (Tab. 24), nejvyšší důležitost vykázala nadmořská výška vypočítaná na základě DTM a dále texturální charakteristiky (variance, mean, entropy) počítané pro jednotlivá spektrální pásma.

proměnná	Důležitost proměnné (%)
Nadmořská výška	55,20
Variance (B2)	34,81
Variance (B4)	31,66
B4	31,61
Mean (B4)	29,22
B2	28,72
Variance (B1)	26,00
Mean (B2)	24,90
B1	24,83
Entropy (B3)	24,59

Tab. 24: Důležitost proměnných pro nejlépe klasifikovaný termín 7.8.2018 (prvních 10)

Porovnání klasifikátorů

Pokud jsou porovnávány využité klasifikátory (MLC, SVM, RF), nejlepších výsledků bylo ve všech případech dosaženo pro data multitemporálního kompozitu, který obsahuje všechny termíny a všechna pásma, které vybraná data poskytují.

Pro všechny klasifikované termíny bylo klasifikací Random Forest pro data PlanetScope, RapidEye i Apex dosaženo vyšších klasifikačních přesností než v případě klasifikace MLC a SVM. Nevyšší přesnosti (80,67 %) bylo ze všech klasifikovaných kombinací dosaženo pro multitemporální kompozit dat PlanetScope z dat korigovaných pomocí QUAC. Nejvyšší přesnosti při klasifikaci jednoho termínu dosáhl termín 7.8.2018 (76,06 %) téhož typu dat s korekcí PlanetScope SR. Data RapidEye byla klasifikována MLC a SVM s vyšší přesností než data PlanetScope (s výjimkou samostatného termínu termínu klasifikovaného MLC). Opačně je tomu ale v případě klasifikátoru Random Forest, kdy vyšších přesností bylo dosaženo pro data PlanetScope. Klasifikace SVM dosáhla nejvyšší přesnosti pro data APEX, MLC a potom pro multitemporální kompozit dat RapidEye. Celkové přesnosti shrnuje Tab. 25.

	PlanetScope			RapidEye			APEX		
	Celková přesnost (%)			Celková přesnost (%)			Celková přesnost (%)		
	MLC	SVM	RF	MLC	SVM	RF	MLC	SVM	RF
Multitemporální kompozit	71,45	69,62	80,67	73,19	72,16	74,75	x	x	x
Jednotlivý termín*	71,04	64,31	76,06	66,07	71,16	73,77	61,39	75,20	75,92

Tab. 25: Porovnání celkových přesností klasifikace pro nejlépe klasifikované termíny

Pozn.: Termíny pro typy dat: PS: 7.8.2018, RE: 27.8.2018, Apex: 10.9.2012

Z Tab. 26 je zřejmé, že s výjimkou zpracovatelské přesnosti pro kategorii smilka tuhá bylo pro všechny kategorie klasifikací Random Forest dosaženo lepší uživatelské i zpracovatelské přesnosti než v případě MLC.

	Zpracovatelská přesnost (%)			Uživatelská přesnost (%)		
	Bezkoleneč	Smilka	Třtina	Bezkoleneč	Smilka	Třtina
MLC	49,22	91,97	31,54	62,43	75,78	56,25
Random Forest	59,24	92,05	69,54	73,28	81,70	84,87

Tab. 26: Porovnání zpracovatelské a uživatelské přesnosti klasifikace dat PlanetScope klasifikátory RF a MLC pro multitemporální kompozit dat PlanetScope

5.3.1.4 Objektová klasifikace

V případě objektového přístupu dosáhl nejvyšší přesnosti multitemporální kompozit (74,13 %). Jeden termín (7.8.2018) byl klasifikován s nejvyšší přesností 69,24 %. V obou případech byly zjištěny horší výsledky než v případě pixelového přístupu. Objektovým přístupem bylo dosaženo lepší zpracovatelské přesnosti při klasifikaci jedné scény pro kategorii bezkoleneč a lepší uživatelské

přesnosti pro bezkolenec a třtinu. V případě multitemporálního kompozitu lepší uživatelské přesnosti dosáhla pouze kategorie bezkolenec. Výsledky jsou shrnuty v Tab. 27.

		Celková přesnost (%)	Kappa	Zpracovatelská přesnost (%)			Uživatelská přesnost (%)		
				1	2	3	1	2	3
Objektová	7.8.2018	69,24	0,43	83,21	58,71	41,22	73,05	52,9	76,25
	MK	74,13	0,51	42,75	89,34	61,13	75	77,63	60,96
Pixelová	7.8.2018	76,06	0,56	55,81	86,13	69,44	66,17	80,05	72,75
	MK	80,67	0,61	59,24	92,05	69,54	73,28	81,7	84,87

Tab. 27: Porovnání pixelové a objektové klasifikace (nejlépe klasifikované soubory – Kompozit 2 a termín 7.8.2018 SR)

Pozn.: 1 – Bezkolenc modrý, 2 – Smilka tuhá, 3 – Třtina chloupkatá, MK – multitemporální kompozit

6 Diskuze

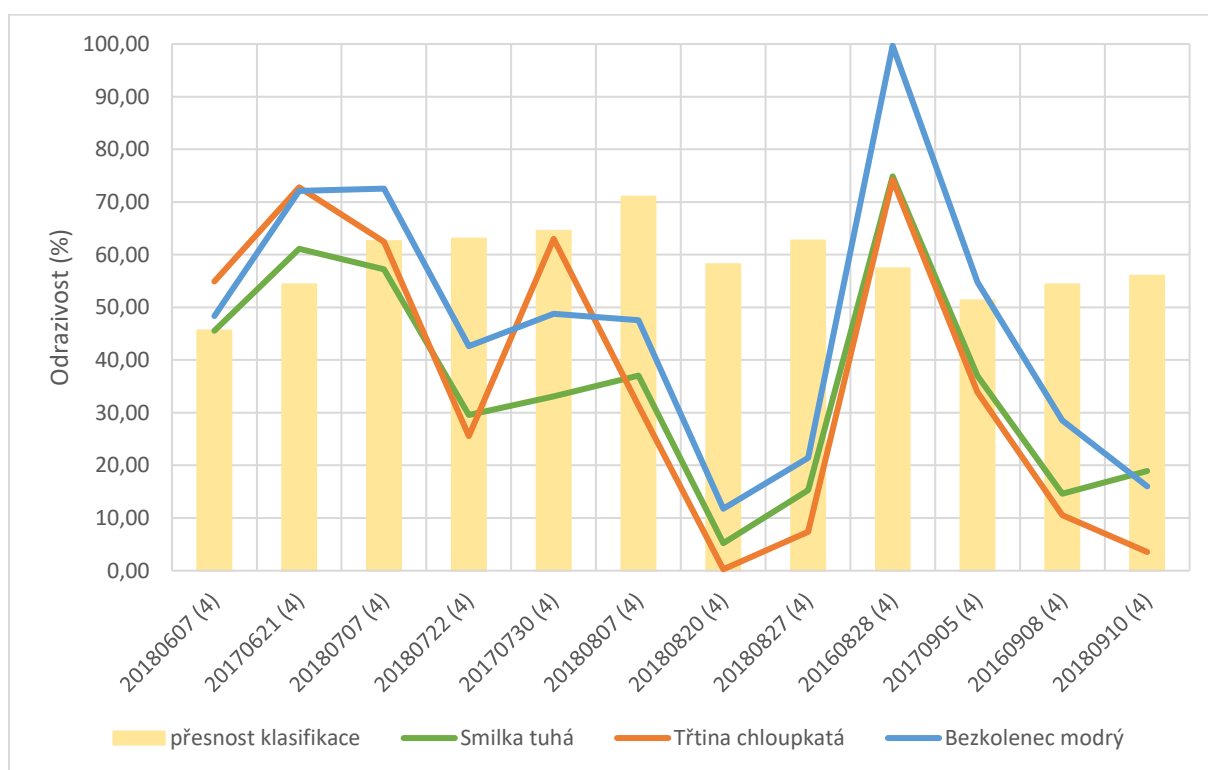
Práce analyzuje možnosti dat PlanetScope pro odlišení tří vybraných druhů jednoděložných trav – bezkolenec modrý (*Molinia caerulea*), třtina chloupkatá (*Calamagrostis villosa*) a smilka tuhá (*Nardus stricta*). Cílem práce bylo také ověřit, zda multitemporální přístup a klasifikátor Random Forest přispěje ke zlepšení přesnosti klasifikace a zda je vhodnější využití pixelové či objektové klasifikace.

Využita byla multispektrální data systému družic PlanetScope, která se vyznačují vysokým časovým (1 den) a prostorovým rozlišením (3 m). Pro porovnání výsledků klasifikace byla hodnocena také multispektrální data družice RapidEye a hyperspektrální data senzoru Apex, jejichž časové, prostorové i spektrální rozlišení je odlišné. Za účelem porovnání přesnosti odlišných metod klasifikace bylo využito klasifikátorů MLC, SVM a RF.

Dílčím cílem práce bylo ověřit přesnost atmosférické korekce dat PlanetScope a vhodnost jejího využití pro klasifikaci sledovaných vegetačních druhů. Na základě dosažených výsledků lze soudit, že odlišné metody atmosférické korekce ovlivňují klasifikační výsledky pouze mírně. Výkyvy v hodnotách odrazivosti, které neodpovídají fenologickým předpokladům, napříč sledovanými termíny mohou být ovlivněny ročním průběhem počasí (srážky, teploty atd.). V případě prvního analyzovaného povrchu, vodní plochy, v průběhu sezóny dochází k jejímu zarůstání, což může zapříčinit změnu spektrálního signálu. Odrazivost druhého povrchu, střechy Luční boudy, by zase mohla být ovlivněna odlišnou intenzitou slunečního svitu v různých termínech, který zapříčiňuje nestálý odraz slunečních paprsků od střešní plochy. Přestože klasifikace termínu 7.8.2018 přinesla lepší výsledky pro data s korekcí PlanetScope SR, multitemporální kompozit dosáhl vyšší přesnosti pro data korigovaná pomocí QUAC. Tento kompozit obsahuje 12 termínů, zatímco kompozit dat SR pouze 10 termínů. Lze tak předpokládat, že multitemporální přístup, zvláště pak rozsáhlá časová řada vhodných termínů (těch, na nichž lze sledovat významné fenologické změny), přináší lepší výsledky a v procesu klasifikace hraje významnější roli než výběr konkrétní metody atmosférické korekce. Za důležitý faktor lze označit také výběr stejné metody provedení atmosférické korekce v rámci multitemporálního kompozitu.

Výsledné přesnosti klasifikace příliš neodpovídají předpokladům zjištěným na základě analýzy spektrálních charakteristik (Obr. 20). Relativně nízká přesnost klasifikace (57,37 %) termínu 28.8.2016, který se jevil jako jeden z nejvhodnějších pro rozlišení problematických kategorií, může ovšem být ovlivněna několika faktory. V tomto termínu je sice navzdory fenologickým předpokladům (zbarvení třtiny chloupkaté do fialova v průběhu srpna oproti nevýraznému chování bezkolenec modrého) výrazně oddělena kategorie bezkolenec modrý, ale třtina chloupkatá a smilka tuhá mají

velmi podobný spektrální signál. Záměna těchto dvou kategorií tedy mohla vést k nižší přesnosti klasifikace. Dalším z důvodů by mohla být odlišná metoda provedení atmosférické korekce pro tento termín než u ostatních termínů. Jak ale bylo zjištěno (viz kapitola 2.7.1), hodnoty odrazivosti v případě odlišných metod provedení atmosférické korekce se sice liší, ale je velmi nepravděpodobné, že by výsledky klasifikace byly tímto faktorem ovlivněny tak výrazným způsobem. Například termín 21.6.2017, pro který je metoda atmosférické korekce stejná jako v případě termínu 28.8.2016, podobně abnormální hodnoty nevykazuje. Hodnoty odrazivosti jsou sice v rámci obou metod odlišné, ale jejich rozdíl zůstává ve všech termínech napříč travinami v podobném poměru, což je pro oddělení jednotlivých druhů při klasifikaci stěžejní. Jako nejpravděpodobnější vysvětlení odlišných hodnot odrazivosti se jeví chyba měření způsobená sezónními výkyvy počasí.



Obr. 20: Průměrná odrazivost trénovacích ploch v NIR a celková přesnost klasifikace MLC dat PlanetScope v jednotlivých termínech

Výsledky spektrální analýzy mohou být do značné míry ovlivněny rozlišeným průběhem vegetační sezóny v analyzovaných letech 2016, 2017 a 2018. Konkrétně se jedná o velmi suchý rok 2018, ve kterém byla sezóna posunuta prakticky o měsíc dopředu oproti normálu (viz kapitola 3.2).

Podle očekávání byl s nejnižší přesností klasifikován bezkolenec modrý, s nejvyšší naopak smilka tuhá. Tyto výsledky byly vzhledem k fenologii sledovaných druhů předpokládány (viz kapitola 3.1). Ke zvýšení přesnosti klasifikace bezkolence modrého by pravděpodobně mohlo napomoci

využití většího počtu trénovacích dat (449 pixelů pro bezkolence modrý oproti 1059 pixelům v případě smilky tuhé). Nejvhodnější pro odlišení bezkolence modrého se ukázal termín 30.7.2017, pro třtinu chloupkatou 5.9.2016 a pro smilku tuhou 7.8.2018.

Lepší celkové přesnosti klasifikace dat PlanetScope (80,67 %) než dat RapidEye (74,75 %) v případě multitemporální klasifikace Random Forest mohou být dány vyšším prostorovým rozlišením dat PlanetScope. Tím, že v klasifikaci Random Forest jsou v úvahu brány i texturní charakteristiky snímku, umožňuje vyšší prostorové rozlišení přesněji popsat vlastnosti jednotlivých kategorií, což může vést k vyšší přesnosti klasifikace. Pokud jsou porovnávány celkové přesnosti multitemporálních kompozitů dat PlanetScope a RapidEye klasifikované metodami MLC a SVM, lepších výsledků data PlanetScope nedosáhla (v případě MLC celková přesnost dat PlanetScope dosáhla 71,45 % oproti 73,19 % u dat RapidEye, resp. 69,62 % oproti 72,16 % v případě metody SVM).

Důležitost prostorového rozlišení byla zjištěna i v Suchá et al. (2016). Výsledky této studie uvádějí, že velmi vysoké prostorové rozlišení dat je zásadním parametrem pro dosažení vysoké celkové přesnosti klasifikace v detailní úrovni.

Výsledky klasifikace multitemporálních kompozitů potvrdily předpoklad zjištěný v kapitole 2.7.1, že důležitým faktorem při klasifikaci sledovaných vegetačních druhů je vysoké časové rozlišení dat, které umožňuje zachytit důležité fenologické fáze sledovaných vegetačních druhů. Data RapidEye, která disponují vyšším spektrálním rozlišením než data PlanetScope, nedosáhla při multitemporální klasifikaci lepších výsledků. Je pravděpodobné, že tato nižší klasifikační přesnost je způsobena nižším počtem termínů v multitemporálním kompozitu dat RapidEye (5 termínů) než kompozitu dat PlanetScope (12 termínů).

Objektový přístup navzdory předpokladům lepší celkové přesnosti nepřinesl. Dílčími úspěchy jsou ale vyšší zpracovatelská i uživatelská přesnost bezkolence modrého v případě klasifikace termínu 7.8.2018 (83,21 % oproti 55,81 %, resp. 73,05 % oproti 66,17 %) a uživatelská přesnost téže kategorie v případě multitemporálního kompozitu (75 % oproti 73,28 %). Dále pak uživatelská přesnost třtiny chloupkaté v případě monotemporální klasifikace termínu 7.8.2018 (76,25 % oproti 72,75 %).

Pokud se týká rozlohy jednotlivých travin, výsledky uvedené v kapitole 5.3.1.1 jsou značně ovlivněny odlišným průběhem sledovaných vegetačních sezón. Z tohoto důvodu nelze činit jednoznačné a přesné závěry ohledně rozrůstání či úbytku klasifikovaných travin.

Nejlepší výsledek klasifikace (celková přesnost 80,67 %), kterého bylo dosaženo pro multitemporální kompozit metodou Random Forest, byl porovnán s nejlepším výsledkem klasifikace dosaženým v Kupková et al. (2017). Tam byla s nejvyšší celkovou přesností (84,31 %) klasifikována

data AISA Dual (40 pásem PCA) klasifikátorem SVM (viz Tab. 28). Přestože v diplomové práci bylo dosaženo nižší celkové přesnosti klasifikace, dílčím úspěchem je vyšší zpracovatelská přesnost pro kategorii smilka tuhá (92,05 % oproti 83,73 %), třtina chloupkatá (69,54 % oproti 55,03 %) a uživatelská přesnost pro kategorii smilka tuhá (81,7 % oproti 71,38 %).

	Zpracovatelská přesnost (%)			Uživatelská přesnost (%)			Celková přesnost (%)
	Bezkoleneč	Smilka	Třtina	Bezkoleneč	Smilka	Třtina	
AISA Dual	66,78	83,73	55,03	75,22	71,38	87,29	84,31
PlanetScope	59,24	92,05	69,54	73,28	81,7	84,87	80,67

Tab. 28: Porovnání výsledků klasifikace RF multitemporálního kompozitu a SVM klasifikace dat AISA Dual (zpracováno dle Kupková et al., 2017)

V porovnání s Marcinkowska-Ochytra et al. (2018a), kde byla testována klasifikace SVM na datech APEX, bylo lepších výsledků v diplomové práci dosaženo pouze v případě uživatelské přesnosti pro kategorii třtina chloupkatá (70 % oproti 62 %). Se stejnou zpracovatelskou přesností byla klasifikována kategorie smilka tuhá (92 %) - viz Tab. 29. Je ale nutné zmínit, že vysoké klasifikační přesnosti zjištěné v Marcinkowska-Ochytra et al. (2018a) mohou být do značné míry ovlivněny odlišnou metodou validace. Referenční data nebyla sbírána pouze v terénu, ale jejich značná část byla odvozena z vegetačních map z roku 2002. Roli hraje v případě porovnání s oběma publikacemi jistě i to, že data PlanetScope jsou multispektrální, kdežto data, pro něž bylo dosaženo vyšších přesností ve zmíněných studiích, byla hyperspektrální.

	Zpracovatelská přesnost (%)		Uživatelská přesnost (%)		Celková přesnost (%)
	Bezkoleneč	Třtina	Bezkoleneč	Třtina	
APEX	94	85	82	62	84
PlanetScope	55	74	75	70	80,67

Tab. 29: Porovnání výsledků RF klasifikace multitemporálního souboru dat a SVM klasifikace dat APEX (zpracováno dle Marcinkowska-Ochytra et al., 2018a)

Klasifikace Random Forest přinesla pro všechny typy dat nejlepší výsledky. K dalšímu zvýšení celkové přesnosti by mohlo vést zařazení dalších proměnných do klasifikačního procesu, například vegetačních indexů, které vhodně charakterizují sledované vegetační druhy. Námětem k další práci by mohlo být také testování širší škály počtu filtrovacích oken při výpočtu texturálních proměnných a dále výběr pouze těch proměnných, které se jeví jako nejvhodnější. Optimalizace volby parametru *n*tree vzhledem k počtu vstupních proměnných by také mohla napomoci ke zpřesnění klasifikace.

7 Závěr

Cílem práce bylo zjistit, do jaké míry jsou data PlanetScope vhodná pro odlišení vybraných druhů jednoděložných travin ve východní části krkonošské tundry a zda multitemporální přístup může přispět ke zpřesnění klasifikace těchto kategorií vegetačního pokryvu. Pro data PlanetScope, RapidEye a Apex proběhla řízená pixelová klasifikace MLC, SVM, RF a objektová klasifikace SVM. Výsledné přesnosti byly porovnány.

Pro analýzu spektrálního chování vybraných vegetačních druhů bylo využito 12 bezoblačných snímků PlanetScope z měsíců červen-zaří ve vegetačních sezónách let 2016, 2017 a 2018. Výsledky spektrální analýzy byly patrně ovlivněny odlišným průběhem jednotlivých sezón, zvláště pak velmi suché sezóny 2018. Typický průběh vegetační sezóny sledovaných druhů byl v tomto roce posunut přibližně o měsíc dopředu (barevné změny vegetace, které se projevují ve spektrálním signálu), což zapříčinilo, že spektrální křivka neodpovídá předpokládanému průběhu fenologie jednotlivých druhů.

Výsledky analýzy spektrálních příznaků sledovaných kategorií (smilka tuhá, třtina chloupkatá a bezkoleneček modrý) ukázaly, že pro odlišení spektrálních příznaků z dat PlanetScope je nejvhodnější pásmo 4 (blízké infračervené) v rozmezí vlnových délek 780-860 nm. Jako nejlépe odlišitelná se jeví kategorie bezkoleneček modrý a jako nejlepší snímek pro klasifikaci byl vyhodnocen termín 28.8.2016. Za vhodné pro klasifikaci lze na základě analýzy průběhu spektrálních příznaků označit srpnové termíny obecně. Tyto výsledky ale nejsou v souladu s klasifikačními přesnostmi.

Přesnosti klasifikací dat s atmosférickou korekcí PlanetScope se od dat, na nichž byla provedena korekce QUAC, významně neliší. Jako vhodné se ukázalo užití stejné metody atmosférické korekce v rámci multitemporálního kompozitu.

Ze všech testovaných typů dat a klasifikátorů bylo nejvyšší celkové přesnosti dosaženo pro multitemporální kompozit dat PlanetScope klasifikátorem Random Forest (80,67 %). Nejlepšího výsledku v případě klasifikace jedné scény dosáhl metodou Random Forest termín 7.8.2018 téhož typu dat (76,06 %). Nejvyšší uživatelské i zpracovatelské přesnosti bylo v obou zmíněných případech dosaženo pro kategorii smilka tuhá. V případě jednotlivého termínu i multitemporálního kompozitu byl nejhůře klasifikován bezkoleneček modrý.

Dále bylo zjištěno, že přesnost klasifikace multitemporálního souboru je v případě dat PlanetScope i RapidEye vyšší než přesnost klasifikace jedné scény. Klasifikátorem Random Forest bylo dosaženo nejlepších výsledků jak v případě klasifikace jednoho termínu, tak multitemporálního kompozitu napříč všemi využitými daty. Pixelovým přístupem bylo dosaženo vyšší přesnosti než v případě objektového přístupu. Hyperspektrální data nepřinesla v porovnání s multispektrálními daty lepší výsledky.

Nejlepší klasifikační výsledek (multitemporální kompozit metodou Random Forest) byl porovnán s výstupy Kupková et al. (2017), kde bylo z dat AISA Dual nejvyšší celkové přesnosti (84,31 %) dosaženo klasifikátorem SVM. Lepších výsledků bylo v této diplomové práci dosaženo v případě zpracovatelské přesnosti u smilky tuhé (92,05 % oproti 83,73 %), třtiny chloupkaté (69,54 % oproti 55,03 %) a užitelské u smilky tuhé (71,38 % oproti 81,70 %). V porovnání s Marcinkowska-Ochytra et al. (2018a), kde bylo z dat APEX a klasifikátorem SVM zjištěna celková přesnost 84 %, dosáhla v práci lepší zpracovatelské přesnosti pouze kategorie třtina chloupkatá (85 % oproti 71 %).

Ukázalo se, že data PlanetScope jsou vhodná pro klasifikaci sledovaných druhů. Byl potvrzen předpoklad, že vysoké časové a prostorové rozlišení těchto snímků přispívá ke zvýšení přesnosti klasifikace vybraných vegetačních kategorií. Využití časové řady dat, kdy lze ze spektrálního projevu jednotlivých termínů pozorovat sezónní odlišnosti vegetace, přispělo k přesnějším klasifikačním výsledkům. Časové a prostorové rozlišení se ukázalo jako důležitější faktor pro přesnost klasifikace než vysoké spektrální rozlišení.

Protože jako zájmové území byla vybrána horská oblast, která je charakteristická častým výskytem oblačnosti, největší úskalí této práce bylo v nedostatečném množství zcela bezoblačných snímků pořízených v rámci jedné sezóny. Jak bylo zjištěno, každá ze třech analyzovaných sezón měla odlišný průběh. Výsledky spektrální analýzy proto nejsou zcela porovnatelné a jejich výstupy nesouhlasí s výsledky klasifikace. Vzhledem k tomu, že klasifikace probíhala na relativně malém území, za další nedostatek lze označit relativně nízké množství referenčních dat.

Na základě zjištěných výsledků se pro klasifikaci jednoděložných travin v krkonošské tundře jeví jako nejvhodnější využití multitemporálního přístupu metodou Random Forest v rámci pixelové klasifikace dat PlanetScope, která jsou atmosféricky korigována metodou QUAC.

Vzhledem k faktu, že multitemporální přístup přinesl lepší výsledky než klasifikace jednoho termínu, dá se předpokládat, že dalšího zlepšení přesnosti by mohlo být dosaženo při využití delší, resp. i hustší časové řady dat PlanetScope v rámci jedné sezóny a dále například při využití dalších proměnných v klasifikátoru Random Forest. Kombinace objektové klasifikace a metody Random Forest by pravděpodobně také mohla přinést dobré výsledky. Posun v klasifikační přesnosti je předpokládán také pro data s lepším zejména prostorovým a spektrálním rozlišením získaná s pomocí UAV.

Použitá literatura

- APEX (200?): APEX-Airborne Prism Experiment. [online]. [cit. 2017-01-15]. Dostupné z: <http://www.apex-esa.org>.
- APEX (2012): Airborne Prism EXperiment. APEX 2012 – September campaign HyMountEcos data delivery report, 2012, 17 s.
- AFIFY, H. A. (2011): Evaluation of change detection techniques for monitoring land-cover changes: a case study in new Burg El-Arab area. *Alexandria engineering journal*, 50(2), s. 187-195.
- ASRAT, Z., TADDESE, H., ØRKA, H., GOBAKKEN, T., BURUD, I., & NASSET, E. (2018): Estimation of Forest Area and Canopy Cover Based on Visual Interpretation of Satellite Images in Ethiopia. *Land*, 7(3), s. 92.
- BLATSCHEKE, T. (2010): Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, č. 1, s. 2–16.
- CAMPBELL, J. B., WYNNE, R. H. (2011): Introduction to remote sensing, 5th edition, The Guildford press. 2011, ISBN 978-1-60918-176-5.
- CAO, G., LI, X., & ZHOU, L. (2016a): Unsupervised change detection in high spatial resolution remote sensing images based on a conditional random field model. *European Journal of Remote Sensing*, 49(1), s. 225-237.
- CAO, G., ZHOU, L., & LI, Y. (2016b): A new change-detection method in high-resolution remote sensing images based on a conditional random field model. *International Journal of Remote Sensing*, 37(5), s. 1173-1189.
- DE OLIVEIRA SILVEIRA, E.M., DE MENENZES, M.D., JÚNIOR, F.W.A., TERRA, M.C.N.S. and de MELLO, J.M. (2017): Assessment of geostatistical features for object-based image classification of contrasted landscape vegetation cover. *Journal of Applied Remote Sensing*, 11(3), s. 1176-1197.
- DOBROVOLNÝ, P. (1998): Dálkový průzkum Země: digitální zpracování obrazu. Brno: Masarykova univerzita, 208 s.
- DOXANI, G., SIACHALOU, S., TSAKIRI-SRATI, M., (2008): An object-oriented approach to urban land cover change detection. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37(B7), s. 1655-1660.
- GEOIMAGE: Rapideye [online]. [cit. 2019-05-11]. Dostupné z: <https://www.geoimage.com.au/satellite/rapideye>
- GIDUDU, A., HULLEY, G., MARWALA, T. (2007): Classification of Images Using Support Vector Machines. Department of Electrical and Information Engineering, University of the Witwatersrand, Johannesburg. 6 s. Dostupné z: <https://arxiv.org/ftp/arxiv/papers/0709/0709.3967.pdf>
- GISGEOGRAPHY (2019): Planet Labs Imagery [online]. [cit. 2019-05-11]. Dostupné z: <https://gisgeography.com/planet-labs-imagery>
- GAO, T., ZHU, J., ZHENG, X., SHANG, G., HUANG, L., Wu, S. (2015): Mapping spatial distribution of larch plantations from multi-seasonal Landsat-8 OLI imagery and multi-scale textures using random forests. *Remote Sensing*, 7(2), s. 1702-1720.

- HARRIS GEOSPATIAL SOLUTIONS (2019): Rule-Based Classification [online]. [cit. 2019-06-17]. Dostupné z: https://www.harrisgeospatial.com/docs/Rule_Based_Classification.html
- HUANG, Z., XU, F., LU, L., NIE, H. (2014): Object-based conditional random fields for road extraction from remote sensing image. In IOP Conference Series: Earth and Environmental Science (Vol. 17, No. 1, p. 012276). IOP Publishing.
- CHEN, G., HAY, G. J., CARVALHO, L. M., WULDER, M. A. (2012): Object-based change detection. *International Journal of Remote Sensing*, 33(14), s. 4434-4457.
- CHYTRÝ, M., KUČERA, T., KOČÍ, M., GRULICH, V., LUSTYK, P. (2001): Katalog biotopů České republiky. Praha: AOPK ČR.
- JAMALI, S., JONSON, P., EKLUNDH, L., ARDO, J., SEQUIST, J. (2015): Detecting changes in vegetation trends using time series segmentation. *Remote Sensing of Environment*, 156, s.182-195.
- JEDRYCH, M., ZAGAJEWSKI, B., MARCINKOWSKA-OCHTYRA, A. (2017). Application of Sentinel-2 and EnMAP new satellite data to the mapping of alpine vegetation of the Karkonosze Mountains. *Polish Cartographical Review*, 49(3), s. 107-119.
- JENÍK, J., ŠTURSA, J. (2003): Vegetation of the Giant Mountains, Central Europe. In: NAGY, L., GRABHERR, G., KÖRNER, CH., THOMPSON, D. B. A. (eds.), *Alpine Biodiversity in Europe (Ecology Studies Vol. 167)*, New York: Springer, s. 47–51.
- 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), s. 29-46.
- KRÁL, K. (2009): Classification of Current Vegetation Cover and Alpine Treeline Ecotone in the Praděd Reserve (Czech Republic), Using Remote Sensing. *Mountain Research and Development*, 29, č. 2, s. 177–183.
- KRNAP (200-?): Krkonošská arko-alpínská tundra [online]. [cit. 2019-04-09]. Dostupné z: <http://www.krnep.cz/krkonoska-arkto-alpinska-tundra/>
- KUBÁT, K. et al. (2002): Klíč ke květeně České republiky. Academia, Praha, 928 s.
- KUHN, M. (2008): Building predictive models in R using the caret package. *Journal of statistical software*, 28(5), s. 1-26.
- KOČÍ, M. (2001): Alpínské trávníky. In: Katalog biotopů České republiky. Agentura ochrany přírody a krajiny ČR, Praha, s. 89–91.
- KOČÍ, M. (2001a): Subalpínská vysokobylinná vegetace. In: Katalog biotopů České republiky. Agentura ochrany přírody a krajiny ČR, Praha, s. 96–100.
- MATHWORKS (2019): Gray Level Co Occurrence Matrix [online]. [cit. 2019-05-11]. Dostupné z: <https://www.mathworks.com/help/images/create-a-gray-level-co-occurrence-matrix.html>
- MARCINKOWSKA-OCHTYRA, A., ZAGAJEWSKI, B., RACZKO, E., OCHTYRA, A., JAROCINSKA, A. (2018a): Classification of High-Mountain Vegetation Communities within a Diverse Giant Mountains Ecosystem Using Airborne APEX Hyperspectral Imagery. *Remote Sensing*, 10(4), s.570.

MARCINKOWSKA-OCHTYRA, A., JAROCINSKA, A., BZDEGA, K. and TOKARSKA-GUZIĆ, B. (2018b): Classification of Expansive Grassland Species in Different Growth Stages Based on Hyperspectral and LiDAR Data. *Remote Sensing*, 10(12), s. 2019.

METEOMANZ (2019): [online]. [cit. 2019-06-17]. Dostupné z: <http://www.meteomanz.com/>.

MÜLLEROVÁ, J. (2005): Use of digital aerial photography for sub-alpine vegetation mapping: A case study from the Krkonoše Mts., Czech Republic. *Plant Ecology*, 175, č. 2, s. 259–272.

PAL, M. (2005): Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), s. 217-222.

PENG, D., ZHANG, Y. (2017): Object-based change detection from satellite imagery by segmentation optimization and multi-features fusion. *International journal of remote sensing*, 38(13), s. 3886-3905.

PETROPOULOS, G. P., ARVANITIS, K., SIGRIMIS, N. (2012): Hyperion hyperspectral imagery analysis combined with machine learning classifiers for land use/cover mapping. *Expert Systems with Applications*, 39, 3800–3809. doi:10.1016/j.eswa.2011.09.083.

PLANET SCOPE (2019): [online]. [cit. 2018-04-8]. Dostupné z: <https://www.planet.com/docs/spec-sheets/sat-imagery/#overview>.

PLANET, 2018. PLANET IMAGERY AND ARCHIVE [online]. [cit. 8. 5. 2019]. Dostupné z: <https://www.planet.com/products/planet-imagery>.

PLANET SURFACE REFLECTANCE PRODUCT (2018): February 2018 [online]. [cit. 2019-06-19]. Dostupné z: https://assets.planet.com/marketing/PDF/Planet_Surface_Reflectance_Technical_White_Paper.pdf

POMAHAČOVÁ M. (2012): Možnosti využití DPZ při monitoringu luční vegetace a managementových zásahů v Krkonoších. Diplomová práce. Katedra aplikované geoinformatiky a kartografie PŘF, Univerzita Karlova v Praze, 65 s.

PYŠEK P. (1993): What do we know about *Calamagrostis villosa*? - A review of the species behaviour in secondary habitats. *Preslia* 65, s. 1-20.

R DOCUMENTATION [online]. [cit. 2019-06-19]. Dostupné z: <https://www.rdocumentation.org/>

RODRIGUEZ-GALIANO, V.F., CHICA-OLMO, M., ABARCA-HERNANDEZ, F., ATKINSON, P.M., JEGANATHAN, C. (2012a). Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. *Remote Sensing of Environment*, 121, s. 93-107.

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

SALAS, E.A.L., BOYKIN, K.G., VALDEZ, R. (2016): Multispectral and texture feature application in image-object analysis of summer vegetation in Eastern Tajikistan Pamirs. *Remote Sensing*, 8(1), s.78.

SILVEIRA, E.M.D.O., MELLO, J.M.D., ACERBI JÚNIOR, F.W., CARVALHO, L.M.T.D. (2018): Object-based land-cover change detection applied to Brazilian seasonal savannahs using geostatistical features. *International Journal of Remote Sensing*, 39(8), s. 2597-2619.

SINGH, A. (1989): Review article digital change detection techniques using remotely-sensed data. *International journal of remote sensing*, 10(6), s. 989-1003.

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

SUCHÁ R., JAKEŠOVÁ L., KUPKOVÁ L., ČERVENÁ L. (2016): Classification of vegetation above the tree line in the Krkonoše Mts. National Park using remote sensing multispectral data. *AUC GEOGRAPHICA*, 51(1): 113–129. DOI: <http://dx.doi.org/10.14712/23361980.2016.10>.

TORTINI R., MAYER, A.L., MAINATI, P. (2015): Using an OBCD approach and Landsat TM data to detect harvesting on nonindustrial private property in Upper Michigan. *Remote Sensing*, 7(6), pp.7809-7825.

TRAGANOS, D., REINARTZ, P. (2018): Interannual change detection of Mediterranean seagrasses using RapidEye image time series. *Frontiers in plant science*, 9, s. 96.

USGS (2019): *Mapping, Remote Sensing, and Geospatial Data* [online]. [cit. 2019-06-19]. Dostupné z: <https://www.usgs.gov/faqs/which-resampling-methods-are-best-preserving-dem-accuracy-and-terrain-characteristics>

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

WEIGH, C. R., ROGGAN, D.N. (2010). Object-based classification vs. Pixel-based classification: comparative importance of multi-resolution imagery. *ISPRS J. Photogramm. Remote Sens*, 38, s. 1-6.

WICAKSONO, P., LAZUARDI, W. (2018): Assessment of PlanetScope images for benthic habitat and seagrass species mapping in a complex optically shallow water environment. *International journal of remote sensing*, 39(17), s. 5739-5765.

YIN, H., PRISHCHEPOV, A. V., KUEMMERLE, T., BLEYHL, B., BUCHNER, J., RADELOFF, V. C. (2018): Mapping agricultural land abandonment from spatial and temporal segmentation of Landsat time series. *Remote Sensing of Environment*, 210, s. 12-24.

YOON, B., CHOI, J. (2018): Analysis of Land Cover Changes Based on Classification Result Using PlanetScope Satellite Imagery." *대한원격탐사학회지*, 34, s. 671-680.

ZAGAJEWSKI, B., KOZŁOWSKA, A., KROWCZYNSKA, M., SOBCZAK, M., WRZESIEN, M. (2005): Mapping high mountain vegetation using hyperspectral data. *EARSeL eProceedings*, 4(1), s. 70-78.


ZHOU, W., TROY, A., GROVE, M. (2008): Object-based land cover classification and change analysis in the Baltimore metropolitan area using multitemporal high resolution remote sensing data. *Sensors*, 8(3), s. 1613-1636.

ZHU, G., BLUMBERG, D. G. (2002): Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel. *Remote sensing of Environment*, 80, č. 2, s. 233–240.

Seznam příloh

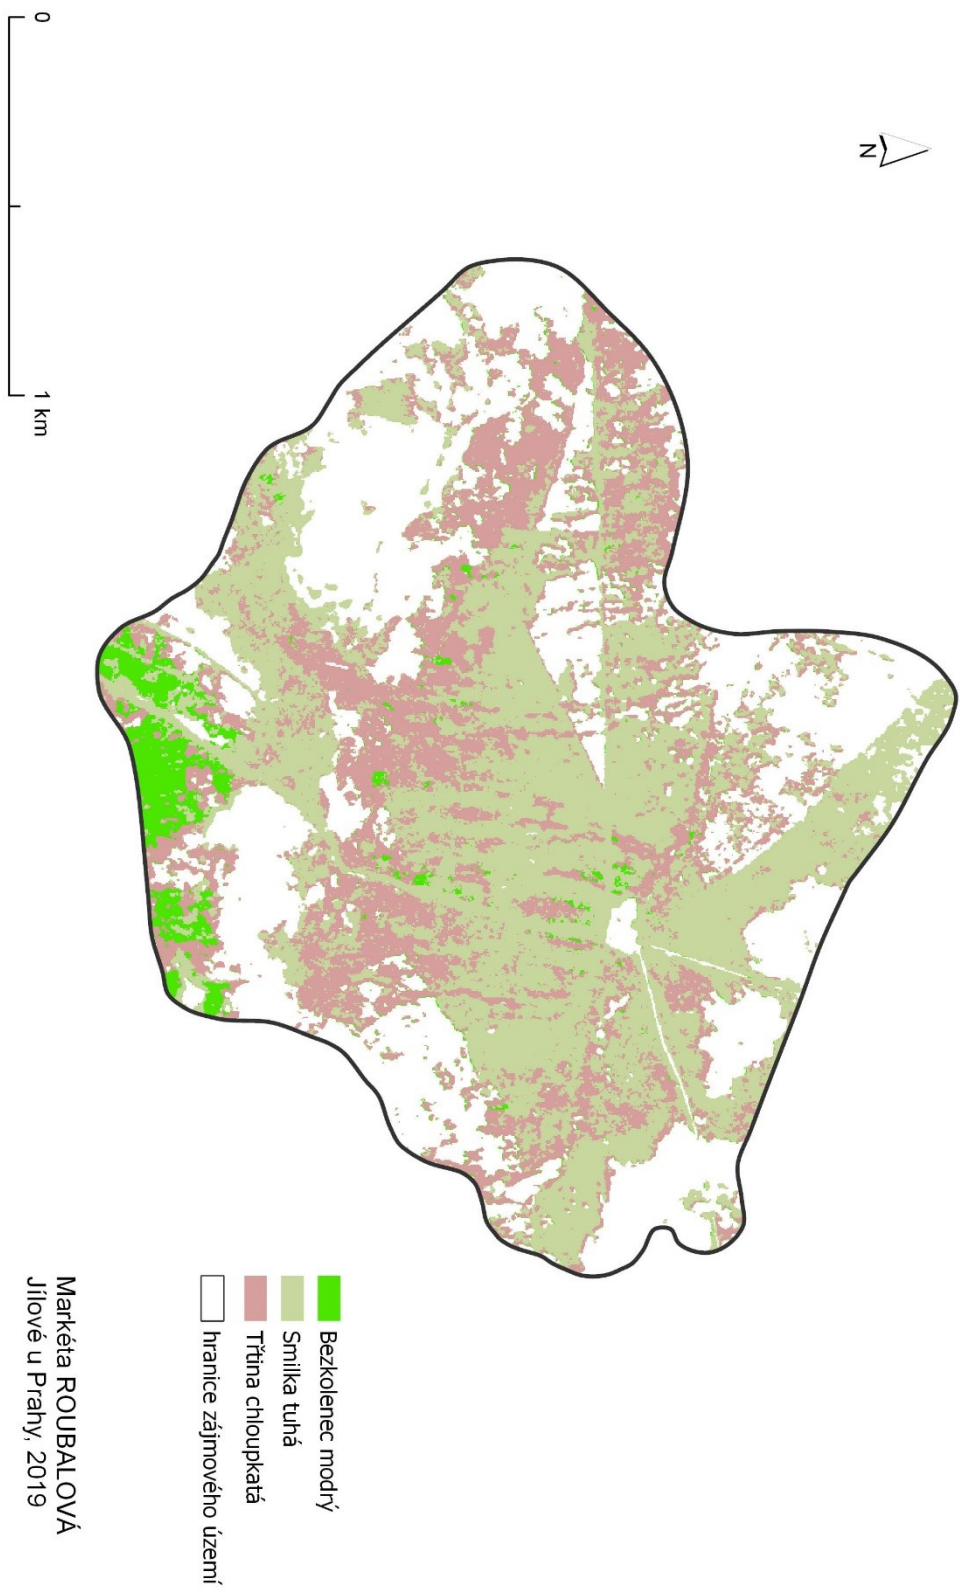
Příloha 1: Výsledek klasifikace MLC dat PlanetScope pro termín 7.8.2018	69
Příloha 2: Výsledek klasifikace SVM dat PlanetScope pro termín 7.8.2018.....	70
Příloha 3 : Výsledek klasifikace Random Forest dat PlanetScope pro termín 7.8.2018.....	71
Příloha 4: Výsledek klasifikace Random Forest dat PlanetScope pro multitemporální kompozit	72
Příloha 5: Výsledek klasifikace Random Forest dat RapidEye pro multitemporální kompozit	73
Příloha 6: Výsledek klasifikace Random Forest dat Apex pro termín 10.9.2012.....	74
Příloha 7: Průměrná odrazivost trénovacích ploch v jednotlivých termínech dat PlanetScope	75
Příloha 8: Obsah přiloženého DVD	76

**KLASIFIKACE VEGETACE VE VÝCHODNÍ ČÁSTI KRKONOŠSKÉ TUNDRY
MLC, PLANETSCOPE, TERMÍN 7.8.2018**




Příloha 1: Výsledek klasifikace MLC dat PlanetScope pro termín 7.8.2018

**KLASIFIKACE VEGETACE VE VÝCHODNÍ ČÁSTI KRKONOŠSKÉ TUNDRY
SVM, PLANETSCOPE, TERMÍN 7.8.2018**



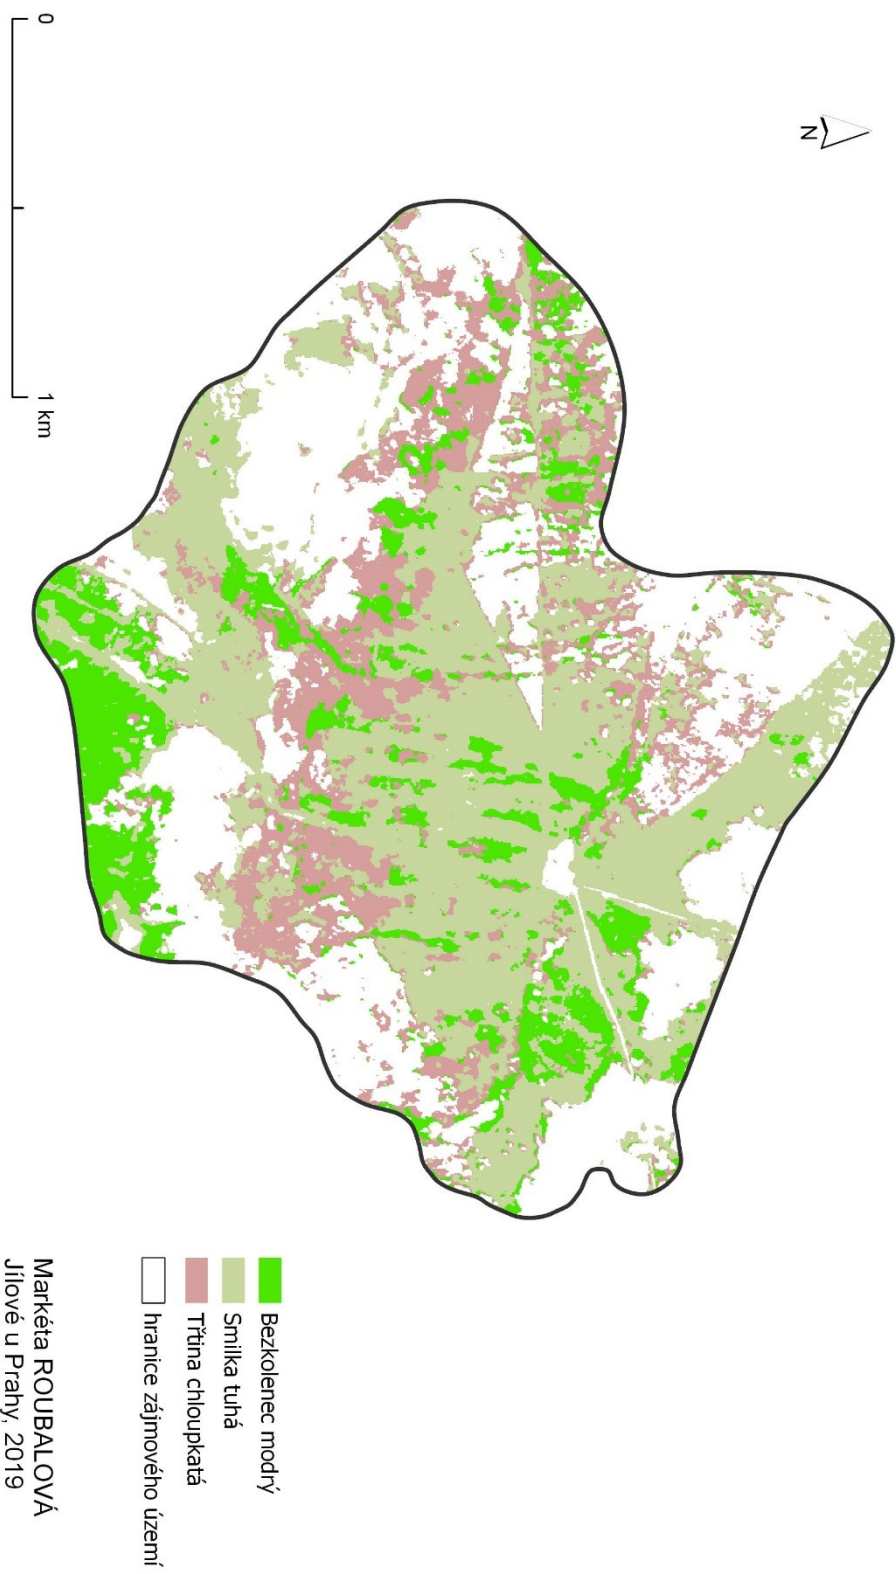
Příloha 2: Výsledek klasifikace SVM dat PlanetScope pro termín 7.8.2018

**KLASIFIKACE VEGETACE VE VÝCHODNÍ ČÁSTI KRKONOŠSKÉ TUNDRY
RANDOM FOREST, PLANETSCOPE, TERMÍN 7.8.2018**




Příloha 3 : Výsledek klasifikace Random Forest dat PlanetScope pro termín 7.8.2018

KLASIFIKACE VEGETACE VE VÝCHODNÍ ČÁSTI KRKONOŠSKÉ TUNDRY RANDOM FOREST, MULTITEMPORÁLNÍ KOMPOZIT DAT PLANETSCOPE




Příloha 4: Výsledek klasifikace Random Forest dat PlanetScope pro multitemporální kompozit

KLASIFIKACE VEGETACE VE VÝCHODNÍ ČÁSTI KRKONOŠSKÉ TUNDRY RANDOM FOREST, MULTITEMPORÁLNÍ KOMPOZIT DAT RAPIDEYE




Příloha 5: Výsledek klasifikace Random Forest dat RapidEye pro multitemporální kompozit

**KLASIFIKACE VEGETACE VE VÝCHODNÍ ČÁSTI KRKONOŠSKÉ TUNDRY
RANDOM FOREST, DATA APEX**



Příloha 6: Výsledek klasifikace Random Forest dat Apex pro termín 10.9.2012



Příloha 7: Průměrná odrazivost trénovacích ploch v jednotlivých termínech dat PlanetScope

Příloha 8: Obsah přiloženého DVD

Prilohy

Priloha1_skripty

- PS_Monotemporal.R
 - Vstupní data: snímek PlanetScope (*“Termín pořízení snímku”*), polygonová vrstva trénovacích polygonů (*“Train”*), digitální model terénu (*“DMT”*), vegetační maska (*“Mask”*)
 - Výstup: snímek klasifikovaný metodou RandomForest

- PS_Monotemporal.R
 - Vstupní data: snímky PlanetScope (*“Termín pořízení snímku”*), polygonová vrstva trénovacích polygonů (*“Train”*), digitální model terénu (*“DMT”*), vegetační maska (*“Mask”*)
 - Výstup: snímek klasifikovaný metodou RandomForest
- Ukazkova_data
 - Vstupni data
 - *“Termín pořízení snímku”* – snímek PlanetScope
 - *“Train”* - polygonová vrstva trénovacích polygonů
 - *“DMT”* - digitální model terénu
 - *“Mask”* - vegetační maska

Priloha2_Text_prace

- Text práce