

Univerzita Karlova

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie

Studijní obor: Kartografie a geoinformatika



Bc. Alex Šrollerů

**MAPOVÁNÍ VEGETACE KRKONOŠSKÉ TUNDRY Z MULTITEMPORÁLNÍCH
LIDAROVÝCH DAT**

***MAPPING RELICT ARCTIC-ALPINE TUNDRA VEGETATION FROM
MULTITEMPORAL LIDAR DATA***

Diplomová práce

Vedoucí práce: Ing. Markéta Potůčková, Ph.D.

Praha, 2021

Vysoká škola: Univerzita Karlova

Fakulta: Přírodovědecká

Katedra: Aplikované geoinformatiky a kartografie

Školní rok: 2021/22

Zadání diplomové práce

pro Alexe Šrollerů

obor Kartografie a geoinformatika

Název tématu: Mapování vegetace krkonošské tundry z multitemporálních LiDARových dat

Zásady pro vypracování

V rámci projektu „Vegetace krkonošské tundry – minulost, současnost a budoucnost“ (2019–2023) probíhá multispektrální, hyperspektrální a LiDARové snímání čtyř experimentálních ploch lišících se druhovým složením vegetace. Mapování travních společenstev, keříčkové a křovinné vegetace s využitím LiDARových dat je v literatuře pouze okrajově řešeným tématem. V rešeršní části diplomové práce budou vytipovány strukturální parametry vegetace odvozené z dat UAV laserového skenování potenciálně vhodné pro rozlišení sledovaných vegetačních tříd krkonošské tundry. Hlavním cílem je určit, které ze strukturálních parametrů mají schopnost odlišit vybrané druhy vegetace, a to mono- i multitemporálně. Dalším úkolem je provést klasifikaci vegetace s využitím strukturálních (LiDAR) a spektrálních (multispektrální data) příznaků, a tak ukázat, zda propojením obou typů dat dojde ke zpřesnění výsledku klasifikace oproti klasifikaci pouze z multispektrálních dat. Posledním úkolem je zjistit, do jaké míry mohou být vybrané strukturální parametry odvozeny z digitálního modelu povrchu získaného obrazovou korelací z multispektrálních dat. Jako modelová území budou použity plochy na Bílé louce a v Úpském rašeliništi.

Rozsah grafických prací: dle potřeby

Rozsah průvodní zprávy: cca 70 stran

Seznam odborné literatury:

Evans, S. J., Hudak, A. T., Faux, R., Alistair, S. (2009): Discrete Return Lidar in Natural Resources: Recommendations for Project Planning, Data Processing, and Deliverables. Remote Sensing, 1, 776-794.

Guo, X., Coops, N. C., Tompalski, P., Nielsen, E. S., Bater, W. C., Stadt, J. J. (2017): Regional mapping of vegetation structure for biodiversity monitoring using airborne lidar data. Ecological Informatics, 38, 50-61.

Kulawardhana, W. R., Popescu, C. S., Feagin, A. R. (2014): Fusion of lidar and multispectral data to quantify salt marsh carbon stocks. Remote Sensing of Environment, 154, 345-357.

Li, A., Dhakal, S., Glenn, F. N., Spaete, P. L., Shinneman, J. D., Pilliod S. D., Arkle, S. R., McIlroy K. S. (2017): Lidar Aboveground Vegetation Biomass Estimates in Shrublands: Prediction, Uncertainties and Application to Coarser Scales. Remote Sensing, 9, 903.

Luo, S., Wang, C., Xi, X., Pan, F., Qian, M., Peng, D., Nie, S., Qin, H., Lin, Y. (2017): Retrieving aboveground biomass of wetland Phragmites australis (common reed) using a combination of airborne discrete-return LiDAR and hyperspectral data. International Journal of Applied Earth Observation and Geoinformation, 58, 107-117.

Streutker, R. D., Glenn, F. N. (2006): LiDAR measurement of sagebrush steppe vegetation heights. Remote Sensing of Environment, 102, 135-145.

Vedoucí diplomové práce: Ing. Markéta Potůčková, Ph.D.

Konzultant diplomové práce: -

Datum zadání diplomové práce: 29. 11. 2019

Termín odevzdání diplomové práce: zima 2021

Platnost tohoto zadání je po dobu jednoho akademického roku.

.....
Vedoucí diplomové práce

.....
Vedoucí katedry

V Praze dne

Prohlášení

Prohlašuji, že jsem závěrečnou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze dne 7. 12. 2021

.....
Alex Šrollerů

Poděkování

Rád bych touto cestou nejprve poděkoval vedoucí mé diplomové práce Ing. Markétě Potůčkové, Ph.D. za věnovaný čas, cenné rady, opravy, připomínky a pochopení. Dále bych chtěl poděkovat dalším členům týmu Laboratorní a obrazové spektroskopie za čas strávený v krkonošské tundře. Z řad studentů, a především kamarádů Gabče Pinlové, která výborně plnila funkci přítele na telefonu. Neméně důležitá byla podpora během studia od rodiny.

Abstrakt

Práce se zabývá parametry vertikální struktury vegetace odvozenými z UAV LiDARových dat a jejich využitím k multitemporální klasifikaci vybraných druhů arкто-alpínské tundry Krkonoš. Na základě rešerše literatury se zaměřením na nízké a keřovité porosty jsou vytipovány strukturální parametry. Jejich vhodnost k rozlišení tundrovité vegetace je hodnocena algoritmem Random Forest a metodou určení důležitosti prediktorů pomocí permutace out-of bag pozorování, vynecháním prediktoru a individuální výkonnosti prediktoru. Následně je provedena fúze s multispektrálními daty a určen vliv LiDAR odvozených strukturálních parametrů na zpřesnění výsledků klasifikace. Zkoumány jsou také strukturální parametry vegetace odvozené z digitálního modelu povrchu získaného obrazovou korelací multispektrálních dat. Pro odlišení vegetačních tříd byl jako nejvhodnější určen parametr maximální výšky, následován minimální výškou, relativním poměrem povrchu vegetace a koeficientem variace, které dosáhly celkové klasifikační přesnosti 67,3 % pro Bílou louku a 62,3 % pro Úpské rašeliniště. Fúze s multispektrálními daty vedla k zpřesnění klasifikace do 2 %. V případě struktury vegetace odvozené z digitálního modelu povrchu bylo dosaženo stejného výsledku s výjimkou vyšších porostů. LiDARová data se neukázala jako přínosná k odlišení travních společenstev, v souladu s literaturou se ukázala jako vhodná pro identifikaci stromové a vyšší vegetace.

Klíčová slova: UAV LiDAR, vegetace, travní společenstva, arкто-alpínská tundra, Krkonoše, klasifikace, random forest.

Abstract

The thesis focuses on metrics of vertical structure of vegetation derived from UAV LiDAR data and their use for multitemporal classification of selected species of arctic-alpine tundra in the Krkonoše Mountains. The metrics are selected based on a literature search focusing on low and shrubby stands. Random Forest algorithm and permutation feature importance, drop column importance and individual predictor performance is used to determine the suitability of metrics for distinguishing tundra vegetation. Subsequently, a fusion with multispectral data is performed and influence of the LiDAR derived variables on the refinement of classification results is determined. The use of metrics derived from a digital surface model obtained by image correlation of multispectral data is also examined. Maximum height followed by minimum height, canopy relief ratio and coefficient of variation yielded the best results, they achieved an overall classification accuracy of 67.3% for Bílá louka meadow and 62.3% for Úpské rašeliniště bog. Fusion with multispectral data led to an increase in overall accuracy up to 2 %. In case of vegetation structure derived from the digital surface model, similar results were achieved apart from higher stands. LiDAR data did not prove to be beneficial in distinguishing grass communities but managed to identify trees and higher stands.

Keywords: UAV LiDAR, vegetation, grasslands, arctic-alpine tundra, Krkonoše Mountains, classification, random forest.

Obsah

Seznam obrázků.....	10
Seznam tabulek.....	11
Přehled použitých zkratk.....	12
1. ÚVOD.....	13
2. ÚVOD DO PROBLEMATIKY A LITERÁRNÍ REŠERŠE.....	15
2.1. LiDAR.....	15
2.1.1. Základní princip LiDARu.....	15
2.1.2. Specifika leteckého laserového skenování.....	16
2.2. Filtrace a klasifikace bodového mračna.....	17
2.3. Aplikace LiDARu pro studium vegetace.....	18
2.4. Strukturní parametry vegetace.....	19
2.5. Fúze laserových a multispektrálních dat.....	25
2.6. Klasifikace vegetace v krkonošské tundře s využitím metod DPZ.....	26
3. DATA A METODIKA.....	30
3.1. Oblast zájmu.....	30
3.1.1. Bílá louka.....	33
3.1.2. Úpské rašeliniště.....	34
3.2. Terénní data.....	35
3.3. Pořízení a předzpracování LiDARových dat.....	35
3.3.1. Hodnocení kvality dat.....	38
3.4. Multispektrální data a digitální model povrchu.....	39
3.5. Metodika.....	40
3.5.1. Výběr a výpočet strukturních parametrů vegetace.....	40
3.5.2. Trénování modelu Random Forest.....	41
3.5.3. Hodnocení důležitosti prediktorů.....	42
3.5.4. Vynechání prediktoru a individuální výkonnost prediktoru.....	43
3.5.5. Kombinace s multispektrálními daty.....	44
3.5.6. Experimentování s digitálním modelem povrchu.....	46
3.5.7. Metriky pro hodnocení klasifikační přesnosti.....	47

4. VÝSLEDKY	49
4.1. Bílá louka	49
4.1.1. Hodnocení kvality dat	49
4.1.2. Korelace a analýza hlavních komponent.....	50
4.1.3. Důležitost prediktorů.....	51
4.1.4. Multitemporální přístup	54
4.1.5. Fúze s multispektrálními daty	56
4.1.6. Digitální model povrchu	59
4.2. Úpské rašeliniště	60
4.2.1. Důležitost prediktorů.....	60
4.2.2. Multitemporální přístup	62
4.2.3. Fúze s multispektrálními daty	64
4.2.4. Digitální model povrchu	66
5. DISKUZE	67
6. ZÁVĚR	71
Použité zdroje.....	72
Seznam příloh	78

Seznam obrázků

Obr. 1: Zájmové území.....	30
Obr. 2: Modelové území Bílá louka.....	33
Obr. 3: Modelové území Úpské rašeliniště.....	34
Obr. 4: Příklad vizuální kontroly polohového přesnosti bodového mračna nad ortofotem z UAV mapování 2020 v oblasti Úpského rašeliniště.	36
Obr. 5: Schéma předzpracování LiDARových dat v softwaru LASTools.....	37
Obr. 6: Vertikální profil bodového mračna.....	38
Obr. 7: Relativní výška porostu jednotlivých druhů vegetace pro Bílou louku.....	41
Obr. 8: Deriváty DMP z Bílé louky.....	47
Obr. 9: Důležitost prediktorů určena metodou permutace out-of-bag pozorování - BL.....	52
Obr. 10: Důležitost prediktorů určena na základě vynechání prediktoru - BL.	53
Obr. 11: Důležitost prediktorů určena permutací out-of-bag pozorování – multitemporálně - BL. 55	55
Obr. 12: Chybová matice nad validačními daty pro prediktory MIN a MAX - BL.	55
Obr. 13: Srovnání výsledků klasifikace celého modelového území pro MS data a jejich kombinace s LiDAR strukturními parametry MIN, MAX - BL.	57
Obr. 14: Chybové matice: MS data + LiDAR strukturní parametry MIN a MAX - BL.	58
Obr. 15: Důležitost prediktorů určena metodou permutace out-of-bag pozorování - UR.	60
Obr. 16: Důležitost prediktorů určena na základě vynechání prediktoru - UR.....	61
Obr. 17: Důležitost prediktorů určena permutací out-of-bag pozorování – multitemporálně - UR. 63	63
Obr. 18: Chybová matice nad validačními daty pro prediktory CRR, CV a MAX - UR.	63
Obr. 19: Srovnání výsledků klasifikace celého modelového území pro MS data a jejich kombinace s LiDAR strukturními parametry CRR, CV, MAX - UR.	65
Obr. 20: Chybové matice: MS data + LiDAR strukturní parametry CRR, CV, MAX - UR.	65

Seznam tabulek

Tab. 1: Strukturní parametry používané při modelování vegetace.	19
Tab. 2: Přehled nadějných strukturních parametrů a jejich využití autory článku.....	24
Tab. 3: Druhy vegetace vyskytující se v modelovém území BL (klasifikační legenda).....	33
Tab. 4: Druhy vegetace vyskytující se v modelovém území UR (klasifikační legenda).	34
Tab. 5: Medián a směrodatná odchylka rozdílů ve výšce kontrolních bodů měřených GNSS a určených z LiDARového snímání.	36
Tab. 6: Vybrané strukturní parametry vegetace.....	40
Tab. 7: Zastoupení tříd v trénovacích datech a vypočtené váhy pro matici chyb klasifikace - BL.	45
Tab. 8: Zastoupení tříd v trénovacích datech a vypočtené váhy pro matici chyb klasifikace - UR.	45
Tab. 9: Hodnoty průměru a směrodatné odchylky pro rozdílové rastry <i>ground</i> mezi měsíci.....	49
Tab. 10: Porovnání výšky vegetace naměřené v terénu a odvozené z LiDARových dat.	49
Tab. 11: Korelační matice strukturních parametrů.	50
Tab. 12: Vlastní vektory, vlastní čísla a vysvětlená variance pro první čtyři hlavní komponenty. .	50
Tab. 13: Hodnoty OOB skóre pro jednotlivé kombinace prediktorů - BL.	51
Tab. 14: Hodnoty OOB skóre při vynechání daného prediktoru - BL.....	52
Tab. 15: Celková přesnost k-fold cross validace pro individuální prediktory – BL.	53
Tab. 16: OOB skóre pro MIN, MAX a model trénovaný nad určitou kombinací měsíců - BL.	56
Tab. 17: Celková přesnost klasifikace pro MS data a LiDAR strukturní parametry vegetace MIN, MAX - BL.	58
Tab. 18: Hodnoty OOB skóre pro jednotlivé kombinace prediktorů - UR.....	61
Tab. 19: Hodnoty OOB skóre při vynechání daného prediktoru - UR.	61
Tab. 20: Celková přesnost k-fold cross validace pro individuální prediktory - UR.	62
Tab. 21: Celková přesnost klasifikace pro MS data a LiDAR strukturní parametry vegetace CRR, CV, MAX - UR.	64

Přehled použitých zkratek

AGB	<i>Aboveground Biomass</i> (množství nadzemní biomasy)
APEX	<i>Airborne Prism Experiment</i> (letecký hyperspektrální senzor)
ASPRS	<i>American Society for Photogrammetry and Remote Sensing</i>
AV ČR	Akademie věd České republiky
BL	Bílá louka
Bpv	Balt po vyrovnání
CART	<i>Classification and Regression Trees</i> (algoritmus pěstování klasifikačních a rozhodovacích stromů)
CZEPOS	Síť permanentních stanic GNSS České republiky
DBH	<i>Diameter at Breast Height</i> (výčetní tloušťka kmene)
DMP	digitální model povrchu
DMR	digitální model reliéfu
DPZ	dálkový průzkum Země
EnMAP	<i>Environmental Mapping and Analysis Program</i> (hyperspektrální družicová mise)
ETRS89	Evropský terestrický referenční systém 1989
GNSS	<i>Global Navigation Satellite System</i> (globální navigační družicový systém)
HS	hyperspektrální
HyMountEcos	<i>Hyperspectral Remote Sensing for Mountains Ecosystems</i> (projekt monitorování ekosystémů KRNAPu s využitím hyperspektrálních dat)
CHM	<i>Canopy Height Model</i> (model výšky porostu)
IMU	<i>Inertial Measurement Unit</i> (inerciální měřicí jednotka)
ISODATA	<i>Iterative Self-Organizing Data Analysis Technique</i> (neřízený klasifikační shlukovací algoritmus)
KRNAP	Krkonošský národní park
LiDAR	<i>Light Detection and Ranging</i> (laserové skenování)
ML	<i>Maximum Likelihood</i> (metoda maximální věrohodnosti)
MNF	<i>Minimum Noise Fraction</i> (transformace dat za účelem redukce dimenzionality a potlačení šumu)
MS	multispektrální
NN	<i>Neural Net</i> (neuronová síť)
OOB score	<i>Out-of-Bag score</i> (metrika pro hodnocení klasifikační přesnosti)
PAI	<i>Plant Area Index</i> (index rostlinné plochy)
PCA	<i>Principal Component Analysis</i> (analýza hlavních komponent)
PPS	<i>Pulse per Second</i> (puls za sekundu)
RF	<i>Random Forest</i> (klasifikační a regresní algoritmus)
RMSE	<i>Root Mean Square Error</i> (odmocnina ze střední kvadratické chyby)
RTK	<i>Real Time Kinematic</i> (kinematická metoda měření polohy v reálném čase)
SVM	<i>Support Vector Machine</i> (metoda podpůrných vektorů)
TIN	<i>Triangulated Irregular Network</i> (nepravidelná síť trojúhelníků)
UAV	<i>Unmanned Aerial Vehicle</i> (bezpilotní letadlo)
UR	Úpské rašeliniště
UTM	<i>Universal Transverse Mercator</i> (Mercatorovo příčné univerzální zobrazení)
VITO	<i>Flemish Institute for Technological Research</i>
VLB	vlčovací body
WGS84	<i>World Geodetic System 1984</i> (Světový geodetický systém 1984)

1. ÚVOD

Přírodovědná hodnota Krkonoš souvisí s jejich výjimečnou polohou uprostřed Evropy, nadmořskou výškou a charakteristickou geomorfologií. Jsou kontaktním místem severské tundry a alpínských ekosystémů, vysokohorských a nížinných prvků (Správa KRNAP, 2010). Daná poloha dala za vznik unikátní krkonošské arкто-alpínské tundře, mozaice ekosystémů s výskytem endemitů, glaciálních reliktnů a zvláště chráněných ohrožených druhů.

V posledních desetiletích dochází v této oblasti k intenzifikaci cestovního ruchu, který má negativní vliv na přírodní prostředí Krkonoš. Kromě toho je území zatíženo velkoplošně působícími imisemi. Vysokohorská vegetace je zvláště ohrožena klimatickou změnou, která se projevuje posunem horní hranice lesa a změnami travních společenstev. Cílem ochrany pro tundrové ekosystémy je zachování jejich dosavadního stavu či obnova přirozeného stavu, a to i do budoucna. Pravidelné monitorování vegetace a identifikace druhů je základem pro splnění daného cíle. V tomto ohledu je velice přesné terénní mapování, které ale je zároveň časově náročné, zvláště pokud je potřeba pokrýt větší území. Technologický pokrok v oblasti DPZ (dálkový průzkum Země) umožňuje snímání s vysokým prostorovým i temporálním rozlišením. Elektromagnetické záření registrované ve smyslu zdroje energie pasivními či aktivními přístroji vytváří speciální charakteristiky zkoumaných objektů a může podpořit tradiční metody mapování vegetace za využití klasifikace snímků (Xie et al., 2008).

Ke klasifikaci vegetace v krkonošské tundře bylo dosud využito dat z RGB, multispektrálních (MS) a hyperspektrálních (HS) senzorů umístěných na leteckých, družicových či UAV (*Unmanned Aerial Vehicle*) nosičích. Snímání v této oblasti probíhá i za pomoci LiDARu (*Light Detection and Ranging*) s cílem zjistit, do jaké míry lze tato data využít ke klasifikaci arкто-alpínské vegetace, resp. jak tato data mohou vylepšit výsledky klasifikace získané ze snímků různého spektrálního rozlišení. LiDAR v oblasti vegetace nachází uplatnění především u lesních porostů, kde vzhledem k 3D charakteru vytvořeného bodového mračka má větší potenciál než tradiční snímání, ať už v inventarizaci lesních porostů a s tím spojenou detekcí stromů, jejich počtu a výšky, průměru kmene, odhadu biomasy a objemu dřeva nebo v určování druhové skladby lesních porostů. Aplikaci LiDARu pro sledování bylinné a keřovité vegetace se věnuje poměrně menší množství studií při porovnání s lesnictvím. Zde slouží např. pro odhad nadzemní biomasy, rozlišení nižších a vyšších porostů či zkoumání struktury vegetace. Ačkoliv samotná klasifikace konkrétních druhů travních společenstev z LiDARu je prakticky neřešené téma, některé práce (Anderson et al., 2018; Kulawardhana et al., 2014; Li et al., 2017) ukazují, že lze identifikovat strukturální parametry vegetace, které jsou citlivé k nízkým porostům. Otázkou také je, zda by metody a parametry používané pro klasifikaci lesních porostů nebylo možno přenést na travní společenstva, za předpokladu existence bodového mračka s extrémní hustotou (blíží se 1 000 bodům/m²).

Vzhledem k tomu, že z LiDARových dat lze odvodit širší spektrum charakteristik o vertikální struktuře vegetace, které nelze získat z jejího spektrálního projevu, řešená diplomová práce vychází z následující hypotézy:

Příznaky charakterizující vertikální strukturu vegetace odvozené z UAV LiDARových dat přispějí ke zvýšení přesnosti klasifikace vybraných druhů arкто-alpínské tundry v porovnání s klasifikací prováděné pouze s využitím MS dat podobného prostorového rozlišení.

Hlavní cíle práce lze shrnout do následujících bodů:

- Na základě rešerše literatury vytipovat strukturní parametry vegetace odvozené z dat UAV laserového skenování, které by bylo možné použít pro rozlišení travních společenstev krkonošské tundry.
- Určit, které z vybraných strukturních parametrů mají schopnost odlišit vybrané druhy vegetace, a to mono i multitemporálně. Rostliny se liší v rámci vegetačního období a kombinace dat z různé fenologické fáze může napomoci k lepší identifikaci.
- Provést fúzi LiDARových a MS dat a ověřit, zda kombinace strukturních a spektrálních příznaků zpřesní výsledek klasifikace oproti klasifikaci MS dat.
- Zhodnotit, do jaké míry lze zpřesnění klasifikace dosáhnout s využitím strukturních parametrů odvozených z digitálního modelu povrchu (DMP) získaného obrazovou korelací z MS dat namísto nákladných LiDARových dat (cena používaného UAV MS senzoru je přibližně desetkrát nižší než cena UAV LiDARu).

2. ÚVOD DO PROBLEMATIKY A LITERÁRNÍ REŠERŠE

2.1. LiDAR

LiDAR či laserové skenování je aktivní technologie dálkového průzkumu, která na základě vysílání pulsního laserového světla (*pulsed wave*) a měření času jeho návratu dokáže určit vzdálenost mezi senzorem a bodem odrazu (Lillesand et al., 2015). Měření vzdálenosti může být prováděno i nepřímo za pomoci měření fázového posunu v kontinuálních vlnách laseru (*continuous wave*). Ze znalosti směru vyslaného laserového paprsku, polohy senzoru a odvozené vzdálenosti lze určit polohu každého měřeného bodu a následně získat 3D reprezentaci povrchu nebo objektu ve formě diskretních bodů, tzv. bodového mračka. LiDAR nachází využití na vesmírných, leteckých, terestrických i mobilních platformách. Mezi jeho výhody patří možnost využití ve dne i v noci, absence geometrické distorze spojené s tradičním fotogrammetrickým snímkováním při projekci 3D světa do dvourozměrného prostoru, vysoká přesnost ve výšce bodu a především schopnost penetrovat skrze porost. (Dong a Chen, 2018)

2.1.1. Základní princip LiDARu

LiDAR jako přístroj se skládá ze zdroje laserového záření (neboli emitoru) s danou vlnovou délkou, optické soustavy, mechanického prvku pro rozmítání laserového paprsku a detektoru elektromagnetického záření. Optická soustava, zpravidla pomocí polopropustného hranolu, koncentruje záření do velmi úzkého svazku a zajišťuje souosost detektoru a emitoru. Aby mohl být pokryt celý objekt či plocha bez nutnosti pootáčení celého zařízení, se pro změnu směru laserového paprsku mimo svou osu využívá rotujícího, nutačního zrcadla, rotujícího hranolu či optických vláken. Hodiny měří čas mezi vysláním paprsků z emitoru a jejich návratem zpět a detekcí detektorem, jsou velmi přesné. (Dolanský, 2004)

V případě častěji používané pulsní modulace vysílač emituje krátké impulsy s pravoúhlým průběhem o délce 10–15 ns (Dolanský, 2004). Světlo prostupuje prostorem se známou a konstantní rychlostí v daném prostředí. Za předpokladu, že světelný paprsek není ovlivněn atmosférickou refrakcí, c je rychlost světla a t_s je tranzitní čas návratu světelného pulzu, lze vzdálenost d mezi povrchem měřeného objektu a senzorem vypočítat na základě vztahu:

$$d = \frac{1}{2} * c * t_s$$

Zaznamenan může být jeden či více odrazů vyslaného pulsu – takové systémy se nazývají diskretní. Dva odrazy od sebe mohou být odlišeny pouze v případě, že jejich vzdálenost je větší než polovina délky pulsu. Na druhé straně fullwaweform systémy zaznamenávají vracející se puls ve fixním časovém intervalu např. 1 ns, který odpovídá 15 cm vzorkovací vzdálenosti, čímž nám poskytují celý profil intenzity odrazu laserového pulsu. (Vosselman a Maas, 2010)

2.1.2. Specifika leteckého laserového skenování

Podle nosiče lze LiDAR dělit na vesmírný, letecký a terestrický, do kterého spadají i moderní mobilní platformy. Pozornost bude věnována leteckému laserovému skenování, pod kterým se dříve rozumělo především skenování z letadla s pevným křídlem nebo vrtulníku. V dnešní době s rozvojem technologie lze snímání provádět i z UAV nosičů, konkrétně například dronů. Ačkoliv se jednotlivé platformy odlišují, jsou založeny na totožném principu. Letecké LiDARy lze dále dělit na topografické a batymetrické, které navíc dokážou penetrovat vodní hladinu s využitím vlnových délek v oblasti zeleného viditelného světla.

Základními komponenty systému pro letecké laserové skenování je dříve popsaná LiDAR jednotka operující v případě terestriální aplikace s infračerveným záření elektromagnetického spektra a kombinace přijímače GNSS (*Global Navigation Satellite System*) a IMU (*Inertial Measurement Unit*). GNSS a IMU jednotka se také nazývá polohový a orientační systém a slouží k přesnému zaměření polohy diferenční metodou, náklonu, směru a zrychlení pohybu pomocí soustavy gyroskopů a akcelerometrů. Dále je nutná kontrolní jednotka, která synchronizuje a řídí celý systém. Vnitřní hodiny této jednotky jsou pravidelně synchronizovány s hodinami GNSS aparatur PPS (*Pulse per Second*) signálem generovaným vnitřními hodinami GNSS přijímače (Dolanský, 2004). Naměřené vzdálenosti jsou s polohou spojeny na základě časových značek. (Dong a Chen, 2018)

Předzpracování dat spočívá v opravě GNSS měřené trajektorie letu o data z IMU a referenční GNSS stanice, pokud již tak nebylo učiněno během letu. V závislosti na naměřených vzdálenostech s časovou značkou a úhlech skenování, IMU, GNSS a kalibračních datech může být zaměřeným bodům přiřazena poloha X , Y , Z v geografickém souřadnicovém systému jako je WGS84 (*World Geodetic System 1984*). Výsledkem měření leteckého laserového skenování je mračno bodů. Dalším krokem může být převod do místního souřadnicového systému, kontrola a vyrovnání leteckých pásů ve výšce, jelikož pro jednoduchost bývají data z překrývajících se linií spojena a uchovávána v jedné bezešvé mozaice. Následně může být určena výšková a polohová přesnost. (Vosselman a Maas, 2010)

LiDARová data bývají nejčastěji ukládána a distribuována ve formátu *las, což je otevřený binární formát sponzorovaný ASPRS (*American Society for Photogrammetry and Remote Sensing*), který se stal v současné době standardem. Umožňuje uchovávat bodové mračno a všechny atributy k němu spjaté. Skládá se z povinné hlavičky, bodových záznamů a volitelných záznamů s proměnou délkou a rozšířených záznamů, které případně obsahují informace fullwaveform. Jeho komprimovanou verzí je *laz nebo proprietární formát *zlas. (Dong a Chen, 2018)

2.2. Filtrace a klasifikace bodového mračna

Zpracování a analýza dat laserového skenování je specifická v závislosti na aplikaci a požadovaných výstupech. Většinou se však neobejde bez základních přístupů filtrace a klasifikace bodového mračna a případné následné interpolace diskretních bodů do kontinuální plochy. Primární objemná data je nutné upravit pomocí automatizovaných, poloautomizovaných funkcí nebo manuální editací.

Pod pojmem filtrace se rozumí klasifikace bodů na reliéf a ostatní, odstranění šumu a odlehlých hodnot. Je to základ pro tvorbu digitálního modelu reliéfu (DMR). Filtrace může být popsána následovně: pro danou sadu bodů P , kde každý bod se nachází v 3D prostoru a má souřadnice X, Y, Z , je nalezena klasifikační funkce c , která přiřadí každému bodu klasifikační označení c . Metody filtrace lze rozdělit podle datového typu na ty, které pracují přímo s bodovým mračnem, a ty, které nejdříve provedou rasterizaci. V případě filtrovacích algoritmů, které operují na rastrové struktuře mohou být využity analogické metody a software, které byly vyvinuty pro zpracování digitálních snímků. Sem patří operace vybírající nejnižší, nejvyšší, průměrné body nebo medián či jednoduché sousedské operace. Nejjednodušší metodou z druhé skupiny algoritmů, která pracuje přímo s bodovým mračnem, je stanovení lokálního minima. Mezi pokročilejší metody můžeme zařadit morfologické filtry, které jsou založeny na konceptu matematické morfologie. Příkladem může být Vosselman (2000), který porovnával vzdálenost a převýšení bodu ve středu filtru se všemi ostatními body v okně, a v případě, že jedna hodnota přesáhla přípustnou hodnotu v dané vzdálenosti, došlo k její vyloučení ze třídy reliéf. Dále lze zmínit robustní interpolaci či progresivní zhušťování TIN (*Triangulated Irregular Network*), kdy je jako reliéf určeno malé procento nejnižších bodů a následně se iterativně zvětšuje množství informace pro klasifikaci celé množiny. Naopak povrchově založené metody většinou začínají s předpokladem, že všechny body náleží reliéfu a následně dochází iterativně k eliminaci bodů, které ploše nenáleží. (Vosselman a Maas, 2010)

Segmentově založená filtrace se liší tím, že na rozdíl od jednotlivých bodů je zde klasifikační entitou celý segment. Metoda se snaží zabránit rozdílnému filtrování bodů náležících stejnému povrchu. Nejčastěji shlukuje body, které mají podobné vlastnosti a náleží stejné rovině, válci nebo jiným jednoduchým tvarům. (Vosselman a Maas, 2010)

Klasifikace přiřazuje bodům nebo segmentům jejich třídu neboli sémantický význam, dochází k rozdělení prvků do tříd na základě definovaných pravidel (Grilli et al. 2017). Klasifikací se tedy rozumí identifikace objektu nebo povrchu, kterému bod náleží. Zpravidla se třídění provádí do tří základních tříd reliéf, budovy a vegetace. Mezi další třídy patří hrubé chyby, body pod reliéfem, nízká vegetace, vysoká vegetace, komunikace, výšková vedení a body terénní kostry (Dolanský, 2004).

2.3. Aplikace LiDARu pro studium vegetace

V případě, že vyslaný laserový puls dopadne na porost, může být odražen zpět k senzoru nebo se vzhledem ke své rozbíhavosti rozprostře dál a pronikne skrze mezery až na reliéf. Právě schopnost LiDARu penetrovat skrze vegetaci a zaznamenat více odrazů je výhodou této technologie a důvod, proč nachází využití především u lesních porostů. V ideálním případě první odraz pochází od vrchní části porostu a poslední odraz by měl reprezentovat reliéf. Mezi tím mohou nastat odrazy od jednotlivých pater. Poloha a intenzita odraženého záření se mění podél cesty paprsku a dává nám informaci o vertikální a horizontální struktuře vegetace.

Primárně slouží data z laserového skenování pro tvorbu DMR na základě filtrace bodů reliéfu, která byla popsána v předchozí části. Z toho může být vypočtena relativní výška bodů vegetace jako rozdíl mezi výškou DMR a výškou každého bodu. Tomuto procesu se někdy říká normalizace bodového mračka či odstranění trendu z DMR (*detrending*). Nad daným bodovým mračnem může být vytvořen grid s určitým prostorovým rozlišením a počítány statistiky výšky bodů spadajících do dané buňky gridu, čímž vznikají rastry vertikální struktury vegetace. Jedním specifickým produktem je CHM (*Canopy Height Model*), který znázorňuje vrchní část porostu tedy maximum výšky. CHM reprezentuje souvislou výšku porostu nejčastěji v rastrovém formátu nebo TIN. Nese podstatnou informaci o množství a prostorové distribuci vegetačního materiálu nad územím a je to základ pro derivaci informací na úrovni stromu. (Dong a Chen, 2018)

Tradiční metody inventarizace lesních porostů jsou časově i pracově náročné. LiDAR nachází využití pro efektivní extrakci potřebných parametrů jako je výška stromu (Lee a Lee, 2018; Su et al., 2012), počet stromů (Pont et al., 2015), objem dřeva (Næsset, 1997), výčetní tloušťka kmene (DBH) (Bucksch et al., 2014). Parametry lze odvodit regresními či jinými statistickými metodami z modelů stromů získaných z CHM nebo na úrovni větších homogenních ploch. Při větší hustotě bodového mračka lze detekovat, segmentovat a modelovat jednotlivé stromy přímo z bodového mračka a počítat dané parametry z nich.

Schopnosti LiDARu v lesních porostech si získaly v posledních letech pozornost v kontextu globálního cyklu uhlíku. Nárůst skleníkových plynů v atmosféře, konkrétně oxidu uhličitého, je diskutované téma. Biomasa se přibližně z 50 % skládá z uhlíku, a především mladé rostoucí lesy jsou jeho přírodní propady. Množství nadzemní biomasy (AGB) je možno získat pomocí měřitelných proměnných jako je výška stromu a DBH s využitím alometrického modelování. (Vosselman a Maas, 2010)

2.4. Strukturální parametry vegetace

Kromě CHM, který charakterizuje maximální výšku porostu, mohou být nad gridem bodového mračna počítány i jiné statistické metriky neboli strukturální parametry vegetace. Tyto metriky mohou posloužit k výpočtu dříve zmíněných parametrů lesních porostů nebo dosud nepokrytým aplikacím LiDARu ve vegetaci. Doporučení pro práci s diskrétními LiDARovými daty v přírodních zdrojích přináší Evans et al. (2009), který definuje pět úrovní zpracování založených na standardech používaných v jiných odvětvích DPZ. Level 0 jsou surová data pořízená senzorem. Produkty Level 1 zahrnují geometrické a senzorové korekce provedené poskytovatelem, projekci a transformaci do požadovaného formátu. Level 2 produkty jsou získány základním post-processingem. Jedná se o klasifikované odrazy reliéfu, DMR, DMP, hodnoty intenzity prvních odrazů, relativní výšky bodů. Level 3 produkty už se využívají pro specifické aplikace a jsou založeny na transformacích, poměrech a jednoduchých výpočtech. Příkladem může být výška porostu, hustota porostu, stratifikovaná hustota porostu. Do Level 4 spadají proměnné odvozené z LiDARových výšek, hustoty, intenzity. Jedná se tedy o samotné strukturální parametry (Tab. 1).

Metrika		Popis
minimum	<i>minimum</i>	minimum(x)
maximum	<i>maximum</i>	maximum(x)
variační rozpětí	<i>range</i>	[maximum(x) – minimum(x)]
aritmetický průměr	<i>arithmetic mean</i>	$\frac{\sum_{i=1}^n x_i}{n}$
směrodatná odchylka (δ)	<i>standard deviation</i>	$\sqrt{\frac{\sum_{i=1}^n (x_i - \frac{\sum_{i=1}^n x_i}{n})^2}{n-1}}$
rozptyl (δ^2)	<i>variance</i>	$\frac{\sum_{i=1}^n (x_i - \frac{\sum_{i=1}^n x_i}{n})^2}{n-1}$
percentil	<i>percentile</i>	5., 10., 25., medián (50.), 75., 95. percentil (x)
medián absolutní odchylky z mediánu		$median_i (X_i - median_j (X_j))$
modus	<i>dominate mode</i>	hodnota převládajícího modu v jádrovém odhadu hustoty (x)
koeficient šikmosti	<i>skewness</i>	$\frac{\sqrt{n} \sum_{i=1}^n (x_i - \mu)^3}{(\sum_{i=1}^n (x_i - \mu)^2)^{3/2}}$
koeficient špičatosti	<i>kurtosis</i>	$\frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^4}{(\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2)^2} - 3$
interkvantilové rozpětí	<i>interquartile range</i>	[75. percentil (x) - 25. percentil (x)]
variační koeficient	<i>coefficient of variation</i>	$(\sigma / \mu)100$
počet modů		počet modů z jádrového odhadu hustoty (x)
rozdíl mezi min a max modem		[max modus - min modus] z jádrového odhadu hustoty (x)
relativní poměr povrchu vegetace	<i>canopy relief ratio</i>	$\frac{\mu(\text{výška}) - \min(\text{výška})}{\max(\text{výška}) - \min(\text{výška})}$
procento odrazů prvních, druhých, třetích, etc.		$\frac{[n_i \text{pořadí odrazu } i]}{N}100$
textura	<i>texture</i>	$\sigma(n_i > \text{výška} (0) \text{ a } <= \text{výška} (1))$
počet <i>ground</i> odrazů		$n \text{ground odrazy} $
počet osatních odrazů		$n \text{ostatní odrazy} $
hustota	<i>density</i>	$\frac{[n_i \text{nonground } i]}{N}100$
stratifikovaná hustota	<i>stratified density</i>	$\frac{[n_i > x_1 \text{ a } < x_2]}{N}100$

Tab. 1: Strukturální parametry používané při modelování vegetace, mohou být počítány z výšky, intenzity nebo hustoty bodů. x = numerická proměnná, n = počet pozorování, μ = průměr, σ = směrodatná odchylka. (Zdroj: Evans et al., 2009)

Klasifikací stromových porostů se zabýval Li et al. (2013), jehož snahou bylo rozlišit jednotlivé druhy dřevin odvozením parametrů 3D textury, rozmístění mezer, relativního stupně shlukování (*relative clustering degree*), relativní míry shlukování (*relative clustering scale*) z korun stromů a následnou lineární diskriminační analýzou. Dalším příkladem může být Falkowski et al. (2009), kde pro charakterizaci jednotlivých stádií sukcese lesa bylo využito strukturních parametrů odvozených z LiDARových dat a klasifikačního algoritmu Random Forest (RF). Byla dosažena vysoká celková přesnost a určeny dva nejdůležitější parametry, a to průměrná výška porostu a pokryvnost (*canopy cover*). Shi et al. (2018) provedl obdobný výzkum v oblasti centrální Evropy pro klasifikaci druhů dřevin. Na strukturních parametrech byla hodnocena korelace, pro klasifikaci bylo využito algoritmu RF a následně došlo k zhodnocení robustnosti a přenosnosti jednotlivých strukturních parametrů. Mezi geometrickými parametry byla nalezena vysoká korelace u maximální, průměrné a směrodatné odchylky, variačního koeficientu, koeficientu šikmosti (*skewness*), 25. a 90. percentilu výšek, průměrné výšky singulárních a prvních odrazů a parametru poměrné výšky porostu (*canopy relief ratio*). Nejlepšího výsledku dosáhla průměrná výška singulárních odrazů. Marselis et al. (2018) se snažil rozlišit jednotlivé vegetační typy v mozaice tropických lesů a savany v Gabonu. Kromě klasických parametrů výšky porostu, byly vytvořeny vertikální PAI (*Plant Area Index*) profily, které znázorňují plochu rostlinného materiálu v m² na m². Algoritmem RF bylo území rozděleno do pěti stádií sukcese vegetace. PAI profily se spolu s průměrnou a směrodatnou odchylkou výšky při vyšším prostorovém rozlišení ukázaly jako vhodní kandidáti pro charakterizaci struktury jednotlivých vegetačních typů.

V oblasti nižších porostů můžeme zmínit Luo et al. (2017), který se snažil odhadnout AGB u mokřadního rákosu. Mokřady jako jeden z nejdůležitějších a nejproduktivnějších ekosystémů země zodpovídají za kvalitu vody, ochranu proti povodním, habitat pro živočichy a obecně mají vysoký ekonomický, kulturní a rekreační význam. Výzkum probíhal v národním parku v Číně, kde v rámci terénního výzkumu byla na určitých místech měřena výška rákosu, množství rostlin a biomasa na plochu. LiDARová data byla pořízena leteckým senzorem s průměrnou hustotou 6,7 bodů na m². Po prvotním automatickém předzpracování dat byla provedena manuální verifikace a reklasifikace se snahou minimalizovat chyby. TIN interpolací LiDAR výškových dat vznikl DMP. Po normalizaci výšek byly vypočteny geometrické parametry minima, maxima průměru, směrodatné odchylky, modu, variance, variačního koeficientu, percentilů výšek, pokryvnost a parametry intenzity fullwaveform. Zkoumán byl i vliv velikosti gridu na výpočet. Samotné modely odhadu biomasy byly založeny na regresní analýze mezi vypočtenými parametry a hodnotami získanými terénním měřením a pro zhodnocení jejich přesnosti byl použit koeficient determinace a RMSE (*Root Mean Square Error*). Výsledkem jsou tři optimální geometrické parametry: maximální výška, směrodatná odchylka výšek a 99. percentil. Existovala závislost výsledku na zvoleném prostorovém rozlišení.

Fúzí MS a LiDARových dat pro kvantifikaci obsahu uhlíku v slaniskách se zabýval Kulawardhana et al. (2014). Hlavními cíli studie byla snaha porozumět interakci mezi diskretním leteckým LiDAR systémem a nízkou bylinnou mokřadní vegetací, určit vhodnou velikost gridu pro danou vegetaci, určit vhodné strukturní parametry odvozené z LiDARu pro odhad výšek a AGB a zhodnotit integraci MS snímků. Výzkum probíhal v oblasti Galvestonského zálivu v Texasu, kde dominuje rod travin *Spartina*. Sběr dat v terénu probíhal systematickým náhodným vzorkováním, aby byly zahrnuty různé variace výšky a biomasy, které plynou z environmentálních a výškových gradientů v dané oblasti. Snímání LiDARových dat probíhalo pomocí leteckého senzoru s průměrnou hustotou 1,4 bodů na m². Prvním krokem byla tvorba DMR. Vzhledem ke struktuře slaništní vegetace, kde je buď reliéf viditelný z vertikální perspektivy nebo se často nad ním vyskytuje mrtvý rostlinný materiál, který ale přibližně reprezentuje zemský povrch, bylo určeno, že některé první odrazy projdou skrze porost a reflektují samotný reliéf. Nejnížší body v rámci specifikovaného okna byly vyfiltrovány a pomocí adaptivní triangulační interpolace na těchto lokálních minimech byl derivován DMR. Odečtením DMR od LiDARových výšek byla zjištěna relativní výška porostu a vypočítány zvolené strukturní parametry vhodné pro nízkou vegetaci. Korelace mezi LiDAR strukturními parametry a naměřenými výškami vegetace byla hodnocena Pearsonovým korelačním koeficientem a korelačními diagramy. K evaluaci kombinace strukturních parametrů, které by mohly lépe predikovat výšku a AGB posloužila vícenásobná regresní analýza. Maximální výška, 90. percentil a průměrná výška vykazovaly nejvyšší shodu s naměřenými hodnotami výšek a biomasy. Kombinací s MS daty bylo dosaženo marginálního zlepšení.

Detekci a charakterizaci vegetace v stepi jihovýchodního Idaho se zabýval Streutker a Glenn (2006). Jedná se o mírně vlněné území ve vyšších nadmořských výškách těsně pod 2000 m n. m., kde dominují keře a traviny. V posledních letech došlo v oblasti ke dvěma kontrolovaným požárům, které změnili ráz krajiny. Cílem bylo zjistit přítomnost křovin a rozlišit místa zasažená požárem. Data byla pořízena leteckým LiDAR senzorem s průměrnou hustotou bodů 1,2 na m². Poskytovatelem bylo provedeno prvotní zpracování dat, jednotlivá letová pásma byla slícována dohromady a registrována pomocí vřícovacích bodů. Došlo k rozdělení bodového mračka do gridu, každá buňka obsahovala rozdílný počet bodů. Vzhledem k výskytu odkrytých holých ploch zemského povrchu posloužil nejnížší bod v buňce pro reprezentaci reliéfu. Interpolací metodou spline vznikl prvotní DMR. Některé body se tím pádem nacházely pod samotným reliéfem, proto byly přidány do kategorie reliéf a proběhla nová iterace. Touto metodou postupně všechny body byly určeny jako reliéf nebo ostatní. Pro všechny body nad reliéfem byla vypočtena relativní výška, výpočet proběhl zvlášť pro všechna letová pásma vzhledem k nepřesnostem mezi překryvy. Následně byla provedena rasterizace a vypočítány strukturní parametry pro jednotlivé buňky: průměrná výška, medián výšek, 95. percentil výšek a směrodatná odchylka výšek. Pro validaci posloužily body posbírané v terénu zaměřené pomocí GNSS, kromě polohy a výšky byl zaznamenán

i druh vegetace. Naměřené hodnoty byly přímo porovnávány s LiDAR vypočítanými strukturními parametry. Jako nejlepší prediktor pro zachycení variability mezi plochami zasaženými a nezasazenými požárem vyšla směrodatná odchylka výšek. Autoři došli k závěru, že není jisté, zda tato metoda dokáže detekovat a charakterizovat jednotlivé druhy travních porostů, a to z důvodu limitace použitého LiDAR senzoru a zpracovatelského postupu.

Houbová společenstva obývají stejné vegetační patro jako traviny. Thers et al. (2017) hledal strukturní parametry, které by mohly sloužit k predikci bohatosti druhů hub a gradientů mezi nimi. Výzkum probíhal v Dánsku v rámci projektu Biowide zaměřeném na biodiverzitu. LiDARová data byla pořízena v období bezlistí leteckým senzorem s průměrnou hustotou 4,6 bodů na m². Bodové mračno bylo klasifikováno na základní kategorie reliéf, budova, voda, nízká/střední/vysoká vegetace, šum a neklasifikováno. Byla vypočtena relativní výška vegetace vůči reliéfu a odstraněny nechtěné antropogenní struktury. Pro jednotlivá místa, kde probíhal pozemní sběr dat, došlo k výpočtu průměru, rozsahu a směrodatné odchylky značného množství strukturních parametrů na gridu. Parametry byly zvoleny na základě předchozích výzkumů v oblasti vegetační struktury. Pomocí statistických metod došlo k vyhodnocení závislosti jednotlivých strukturních parametrů. Množství druhů hub stoupá spolu s vegetační komplexitou. Jako nejlepší parametry pro určení bohatosti výskytu vyšla pokryvnost, průměrná výška porostu a procento odrazů od země na m².

Struktura vegetace je důležitý indikátor biodiverzity. Nový přístup k zpracování LiDARových dat na regionální úrovni za účelem tvorby inventáře vegetační struktury přinesl Guo et al. (2017). Inventář by měl syntetizovat vertikální variaci vegetace do kategoričkových tříd pro použití při ochraně přírody. Výzkum probíhal v provincii Alberta v Kanadě se zaměřením na podhůří a boreální lesy, které jsou často využívány pro těžbu dřeva, a tak tvoří fragmentovanou krajinu. LiDARová data byla pořízena leteckým systémem s hustotou 1 až 4 bodů na m². Výška bodů nad terénem byla normalizována na základě získaného DMR z daných dat. Byl generován grid strukturních parametrů vegetace založený na normalizovaných prvních odrazech. Dále bylo vybráno 6 strukturních parametrů používaných v oblasti biodiverzity, a to směrodatná odchylka výšek, pokryvnost a hustota porostu v rámci určitého rozsahu výšek, které byly stanoveny, aby charakterizovaly rozložení druhů fauny do jednotlivých výškových pater. Pro interpretaci vegetačních atributů a režimů disturbance pro LiDAR založenou strukturní klasifikaci bylo využito databáze historických požárů s polygony požárů, databáze antropogenních disturbancí a pravidelných snímků z dané oblasti. Data byla analyzována metodou dvou krokového shlukování. Strukturní parametry pokryvnost a hustota porostu v určité výšce (*canopy height density*) se ukázaly jako nejvíce vlivné pro oddělení jednotlivých strukturních tříd. Směrodatná odchylka výšek podle autorů není tak významná, protože vykazuje stupeň kolinearity s ostatními parametry.

Výzkum Anderson et al. (2018) se zabýval pozemním laserovým skenováním a metodami strojového učení pro modelování a mapování porostu a AGB nízké vegetace. Jednalo se o oblast severovýchodního Idaho, USA. Místní flora se skládá z travin a menších keřů nepřesahujících výšku 1,5 metru. V oblasti dochází k častým požárům, které způsobily náhradu původních společenstev nepůvodními druhy travin. Snímání proběhlo během vegetační sezóny na náhodně rozložených plochách. Při sběru pozemních dat došlo k identifikaci vyskytujících se druhů a odběru biomasy. Bodové mračno bylo převzorkováno s danou minimální vzdáleností mezi body, odstraněn byl šum a kvadráty reprezentující vlíčovací body. Došlo k iterativní filtraci na reliéf a vegetaci a výpočtu strukturních parametrů vertikálního rozložení bodů vegetace na třech různých velikostech pixelu. Klasifikační algoritmus RF posloužil pro vytvoření modelů predikujících druh porostu a AGB. Jako prediktor byl vybrán nejsilnější strukturní parametr a následně byly přidávány další strukturní parametry v pořadí, dokud docházelo ke zvyšování přesnosti. Pro mapování travních společenstev se nejvíce osvědčil medián výšek, maximální výška a variační koeficient. Důležité je zmínit, že nedocházelo k explicitní klasifikaci a vymezení individuálních druhů vegetace, ale pouze výpočtu zastoupení jednotlivých druhů porostu. Jedná se tedy o modelování vegetace per-area.

Cílem studie Li et al. (2017) bylo modelovat AGB v keřovité stepní krajině a prozkoumat nejistoty spojené s danými vytvořenými modely. Výzkum probíhal v oblasti planin v severovýchodním Idaho, USA. Dominují zde především nízké keře a mozaika travních společenstev ovlivněna požáry. Sběr dat probíhal na plochách, kde byly zachyceny různé krajinné rázy. LiDARová data byla pořízena leteckým senzorem. Prvním krokem byla filtrace bodů na reliéf a vegetaci stanovením prahové hodnoty pro reliéf a pro mezery v porostu. Z bodů reprezentujících vegetaci byly vypočteny strukturní parametry založené na numerických hodnotách výšky porostu a hustotě bodů. Kromě samotného výpočtu na bodovém mračnu byl zkoumán vliv rasterizace na výpočet. K zjištění vztahu mezi strukturními parametry a AGB naměřeném v terénu bylo využito RF. Všechny parametry prošly iniciálním během a následně byly seřazeny podle jejich předpovídajících schopností. Kromě metody RF byla využita i stepwise regrese, která vybírá nejdůležitější nezávislé proměnné. Ty jsou přidávány do rovnice jedna po druhé v závislosti na daných statistických kritériích. Pokud přidání další proměnné nevylepší výsledek, proces končí. Vzhledem k výsledkům bylo doporučeno převod na rastr využívat pouze v případě vysokého prostorového rozlišení. Model s nejvyšším koeficientem determinace AGB určil strukturní parametry směrodatné odchylky, koeficientu šikmosti a mediánu absolutní odchylky z mediánu výšek.

Přehled strukturních parametrů určených jako důležitých a produkujících pozitivní výsledky v daných aplikacích je znázorněn v Tab. 2.

Strukturní parametr	Článek	Využití
průměrná výška (<i>mean</i>)	Falkowski et al. (2009), Marselis et al. (2018), Shi et al. (2018), Kulawardhana et al. (2014), Thers et al. (2017)	klasifikace stádií sukcese lesa, vegetačních typů, druhů dřevin bohatost hub
směrodatná odchylka výšky (<i>standard deviation</i>)	Li et al. (2017), Marselis et al. (2018), Luo et al. (2017), Streutker a Glenn (2006), Anderson et al. (2018), Li et al. (2017)	AGB; klasifikace vegetačních typů, variability nízkých porostů; zastoupení druhů
x. percentil výšky (99, 90, 50)	Luo et al. (2017), Kulawardhana et al. (2014), Anderson et al. (2018), Li et al. (2017)	AGB; zastoupení druhů
maximální výška (<i>maximum</i>)	Luo et al. (2017), Kulawardhana et al. (2014), Anderson et al. (2018)	AGB
koeficient šikmosti (<i>skewness</i>)	Li et al. (2017)	AGB
pokryvnost (<i>canopy cover</i>)	Falkowski et al. (2009), Thers et al. (2017), Guo et al. (2017)	klasifikace stádií sukcese lesa; bohatost hub; struktura vegetace
hustota porostu v určité výšce (<i>canopy height density</i>)	Guo et al. (2017)	struktura vegetace

Tab. 2: Přehled nadějných strukturních parametrů a jejich využití autory článku.

2.5. Fúze laserových a multispektrálních dat

Mnoho aplikací v dálkovém průzkumu si vystačí s jedním zdrojem dat, avšak schopnost interpretovat zemský povrch se většinou vylepší, pokud se použije více než jeden typ prostorových dat. Každý senzor měří jinou charakteristiku povrchu, a tak se navzájem doplňují. Fúze dat může vést k dosažení lepších výsledků zkoumaného jevu (Richards, 2013). Při kombinaci dat dálkového průzkumu z více senzorů je nutné zařídit, aby všechny datasety byly přesně registrované a převzorkované na stejnou velikost pixelu (Jensen, 2015).

Přínosem fúze družicových MS a leteckých laserových dat se zabýval Kukunda et al. (2018) při klasifikaci dvou druhů borovic, které jsou špatně odlišitelné v terénu i ze snímkování dálkového průzkumu. Integrace obou datasetů vedla k spolehlivějším mapám jejich rozšíření. Zařazení LiDAR odvozené výšky vegetace do klasifikace dřevin v Jižních Alpách vedlo k zvýšení celkové přesnosti o 7–8 % (Dalponte et al., 2012). Dechesne et al. (2017) se zaměřil na celé homogenní porosty s dominantní jednou dřevinou a fúzí dat dosáhl o 15 % větší celkové přesnosti klasifikace. Vybrané výzkumy potvrzují vhodnost kombinace dat leteckého laserového skenování pro lesní porosty.

V oblasti volných pastvin, kde hlavní tři typy vegetace tvoří opadavé lesy, křoviny a traviny, Bork a Su (2007) ke klasifikaci MS dat přidali produkty DMR a DMP odvozené z LiDARu. Kromě tří základních typů vegetace bylo klasifikováno i osm detailních vegetačních tříd. Sami o sobě si LiDARová data vedla hůře, ale při integraci s MS daty došlo ke zlepšení celkové přesnosti MS dat o 16 až 20 %. V případě, že nějaká třída byla dobře identifikovatelná z jednoho zdroje dat, pak byla extrahována a nezasáhla již do společné klasifikace. Vysoké celkové přesnosti klasifikace může být dosaženo i v komplexní krajině.

Úspěch přinesla i kombinace LiDARových a MS dat v porostech mangrovů. Přidáním informace o vertikální struktuře vegetace několika vrstvených mangrovů do klasifikace druhů způsobilo nárůst celkové přesnosti MS dat z 70–78 % na 81–88 % v závislosti na použitém klasifikátoru. Spektrální příznaky z optických dat a strukturní příznaky z LiDARových metrik byly navzájem komplementární. (Li et al., 2021)

Kromě klasifikace tříd vegetace našla fúze pozitivní využití i pro mapování habitatu komárů v urbánních oblastech (Hartfield et al., 2011), charakterizaci struktury lesa (Manzanera et al., 2017), odhadu objemu a biomasy u opadavých a listnatých lesů (Popescu et al., 2004) nebo mapování prevalence stěhovavých pěvců v opadavých lesech (Swatantran et al., 2012).

2.6. Klasifikace vegetace v krkonošské tundře s využitím metod DPZ

Výzkumné a publikační činnosti se v oblasti krkonošské tundry věnují odborníci na DPZ na obou stranách státní hranice. Na české straně se jedná především o členy katedry aplikované geoinformatiky a kartografie z Přírodovědecké fakulty Univerzity Karlovy, na straně polské je zainteresována katedra geoinformatiky, kartografie a DPZ z Fakulty geografie a regionálních studií Varšavské univerzity. Vybrané články pokrývají všechny přístupy dálkového průzkumu, které doposud byly využity ke klasifikaci vegetace krkonošské tundry. Jedná se o data MS, HS, jejich kombinaci a v jednom případě byla snaha rozlišit traviny i za pomoci LiDARu.

Mezi první publikace patří Müllerová (2005), která se snažila zmapovat a analyzovat změny subalpínské krkonošské vegetace z MS leteckých snímků z let 1986, 1989 a 1997. Snímky s prostorovým rozlišením 1 m byly oskenovány a digitálně upraveny. Provedeno bylo vyrovnání histogramu, transformace PCA (*Principal Component Analysis*), výpočet normalizovaných vegetačních indexů a následně proběhla neřízená klasifikace ISODATA (*Iterative Self-Organizing Data Analysis Technique*) a řízená klasifikace ML (*Maximum Likelihood*). Pro tři nemíchané třídy z šesti bylo při neřízené klasifikaci dosaženo celkové přesnosti 60,6 %, pro 9 tříd řízené klasifikace z nichž z vegetace se jednalo o borovici kleč, traviny s dominantní smilkou tuhou, vysoké květnaté traviny a vegetaci podél cest, bylo dosaženo přesnosti 81,1 %. Letecké snímky se oproti tradičnímu terénnímu mapování ukázaly jako méně detailní a schopné klasifikovat pouze dominantní druhy. Menší plochy heterogenní či atypické vegetace byly obtížně rozlišitelné. I přes tyto nedostatky autorka shrnuje, že se jedná o vhodnou metodu pro tuto zájmovou oblast s výrazným prostorem pro zlepšení.

Potenciál MS dat pořízených různými senzory, které se liší prostorovým i spektrálním rozlišením, zkoumala Suchá et al. (2016). Konkrétně se jednalo o letecké ortofoto s rozlišením 12,5 cm a 4 pásmy, snímky WorldView-2 s rozlišením 2 m a 8 pásmy, snímky Landsat 8 s rozlišením 30 m a 7 pásmy. V oblasti východní i západní krkonošské tundry byla vytvořena podrobná klasifikační legenda reprezentující jednotlivé druhy vegetace a zjednodušená legenda popisující obecně vegetační typy. Kromě dat z různých senzorů byly využity i rozdílné metody per-pixel a objektové klasifikace: ML, SVM (*Support Vector Machine*) a NN (*Neural Net*). Výsledky ukázaly, že nejvyšší přesnosti bylo dosaženo v případě objektově orientované SVM a snímků s nejvyšším prostorovým rozlišením, a to 83,56 % pro zjednodušenou a 71,96 % pro detailní legendu. Z dat WorldView-2 byla při per-pixel klasifikaci SVM dosažena přesnost 68,30 % a dat Landsat při per-pixel klasifikaci ML 78,31 %. Výsledky klasifikace byly ovlivněny různým počasím a vegetačním obdobím, během kterého byly snímky pořízeny. V případě zaměření se na jednotlivé druhy vegetace lze říct, že klasifikace byla úspěšná pro zástupce rodu brusnice a většinou i borovici kleč. Na druhé straně méně uspokojivých výsledků dosáhly traviny s podobnými spektrálními

příznaky třtina chloupkatá, metlice trsnatá a bezkolnec modrý. Byl vyvozen závěr, že snímky Landsat jsou vhodné pro získání obecného přehledu o zastoupení land cover nad horní hranicí lesa. Nebyl nalezen kompromis, který by byl vhodný pro všechna data a metoda by tedy měla být volena v závislosti na prostorovém rozlišení a detailnosti dat. Zároveň vysoké prostorové rozlišení je základ do budoucna pro vyšší celkovou přesnost.

Marcinkowska-Ochtyra et al. (2020) se zaměřila na MS snímky s prostorovým rozlišením v rozmezí 10 a 20 m z mise Sentinel-2. Cílem bylo klasifikovat osm vegetačních typů v západní a východní tundře. V terénu byly zaměřeny referenční polygony vegetace sloužící jako trénovací a validační data. Z databáze Sentinel-2A snímků byly vybrány čtyři snímky bez oblačnosti z různé fáze vegetačního období. Z těchto snímků následně byly odvozeny další proměnné, a to PCA pásma a vegetační indexy. Porovnávány byly mono i multitemporální klasifikace algoritmem SVM. Kvantifikace výsledků proběhla na 100 iteracích algoritmu. Celková přesnost pro multitemporální datasety se pohybovala v rozmezí 76,3 % a 79,5 % a byla vždy vyšší než v případě jednotlivých termínů. Přidání PCA pásem a vegetačních indexů jako proměnných do klasifikace nepřineslo zlepšení výsledků. Borovice zakrslá se ukázala jako třída s nejvyšší přesností.

Se Sentinel-2A daty ze stejné oblasti pracovala také Kupková et al. (2017) spolu s leteckými HS snímky ze senzorů AISA Dual a APEX (*Airborne Prism Experiment*) pořízenými v letech 2012 a 2013. Ke klasifikaci byly použity přístupy per-pixel i objektové klasifikace: ML, SVM, NN. Referenční data byla identifikována botaniky a zaměřena GNSS systémem. Některé kategorie jako borovice kleč, smrk ztepilý a voda byly získány manuální vektorizací z ortofota. Detailní legenda definující druhy travin, vyšší a další vegetace a neživé složky byla využita pro HS data. Pro Sentinel-2A snímky byla z důvodu nižšího prostorového rozlišení použita zjednodušená legenda odpovídající Suchá et. al (2016), která zahrnuje dvě třídy borovice kleče v závislosti na hustotě pokrytí, kamenná moře a antropogenní plochy, smrk ztepilý, uzavřené alpské trávníky s dominantní smilkou tuhou, traviny a vegetace rodu brusnice, alpské vřesoviště, mokřady a rašeliniště. APEX snímky pocházely ze září a AISA Dual z června. Došlo u nich k transformaci na PCA pásma z důvodu redukce dimenzionality dat a vyhnutí se redundanci informací. Volně dostupný Sentinel-2A byl pořízen v srpnu. Při klasifikaci byla zkoumána různá nastavení parametrů jednotlivých algoritmů a kombinace pásem. Jednalo se ale pouze o monotemporální přístup. Nejlepšího výsledku bylo dosaženo v případě AISA Dual pomocí per-pixel SVM klasifikace pro 40 PCA pásem, a to celkové přesnosti 84,3 %. APEX dosáhl nejlepšího výsledku pouze o 1,7 % nižšího. U Sentinel-2A nejvyšší celková přesnost byla 77,7 % u per-pixel klasifikace ML. V případě detailní legendy si nejlépe vedla kamenná moře a antropogenní plochy, vodní plochy a borovice kleč. Z travin byla špatně identifikovatelná třída druhově bohaté vegetace s vysokým podílem lučních bylin. Smilka tuhá a metlice trsnatá produkovala poměrně dobré výsledky, středně na tom byly míchané travní porosty třtiny chloupkaté a bezkolence modrého.

Celé pohraniční území KRNAP (Krkonošský národní park) ze Sentinel-2 snímků klasifikoval Jędrych et al. (2017) spolu se simulací budoucí HS družice EnMAP (*Environmental Mapping and Analysis Program*). Osm vegetačních typů bylo s nejvyšší přesností 82 % určeno metodou SVM z transformovaných PCA pásem, z toho nejhůře dopadla právě třída travin.

Spektrální rozlišitelnost uzavřených alpínských trávníků s dominantní smilkou tuhou a kompetitivních travin třtiny chloupkaté a bezkolence modrého se zabývala Červená et al. (2020). Měření probíhalo na úrovni listu, úrovni porostu a úrovni snímku třikrát během vegetační sezóny. Z toho právě úroveň snímku byla získána metodami dálkového průzkumu. HS snímky byly pořízeny senzorem Nano-Hyperspec na dronu DJI Matrice 600 Pro. S využitím metody analýzy variance a nepárového Welchova t-testu bylo zjištěno, že je rozdíl mezi výsledky pro všechny tři zdroje spekter. Ze všech metod bylo nejlepší rozlišitelnost travin dosaženo na úrovni snímku v červenci.

APEX je HS senzor s 288 spektrálními pásmy a prostorovým rozlišením 1,75 až 3,5 m v závislosti na výšce letu. Aplikace APEXu v krkonošské tundře je poměrně hodně řešené téma, všechny výzkumy vycházejí z leteckého snímání ze září roku 2012 provedeného týmem VITO (*Flemish Institute for Technological Research*) v rámci projektu HyMountEcos (*Hyperspectral Remote Sensing for Mountains Ecosystems*). Projekt zahrnuje české a polské instituce a jeho hlavním cílem bylo pořídit HS data české a polské části Krkonoš a zároveň provést referenční terénní měření. Velké homogenních plochy vegetace byly zaměřeny GNSS systémem spolu s jejich spektrálními charakteristikami pro atmosférickou korekci. Marcinkowska et al. (2014) si vybrala oblast v okolí hory Szernica v západních Krkonoších. Pro 15 vegetačních druhů dosáhla algoritmem SVM celkové přesnosti 79,13 %. Jarocińska et al. (2016) se na rozdíl od předchozí studie zabývala pouze stavem vegetace, a to nad horní hranicí lesa v blízkosti Velké a Malé Úpy. V terénu byl doměřen index listové plochy, frakce absorbovaného fotosynteticky aktivního záření a obsah chlorofylu. Došla k závěru, že synantropní komunity vegetace jsou v lepší kondici než přírodní. Na oblast východních Krkonoš kolem Malého Stawu se zaměřila Marcinkowska-Ochtyra et al. (2017). Klasifikovala 21 vegetačních druhů a 8 obecných vegetačních typů s využitím algoritmu SVM na všech pásmech a po provedení MNF (*Minimum Noise Fraction*) transformace, která ale neprodukovala lepší výsledky. Pro detailní legendu dosáhla celkové přesnosti 74,39 %, pro obecné vegetační typy 90,72 %. Zároveň zkoumala potencionál EnMAPu. Celé hraniční pásmo KRNAPu zmapovala Marcinkowska-Ochtyra et al. (2018b.). Zvolila hned tři přístupy, klasifikaci na všech pásmech, MNF a PCA transformaci. Pro 22 vegetačních druhů vyšla nejlépe SVM klasifikace z PCA pásem s celkovou přesností 84 %. Všichni autoři se shodují na obtížně a jednoduše klasifikovatelných druzích. Mezi dobře identifikovatelné druhy vegetace, které měli uživatelskou a zpracovatelskou přesnost nad 80 % lze zařadit lišejníky mapovník alpský a pupkovku válcovitou, borovici kleč, brusnicovou vegetaci a vysokostébelné traviny. Naopak obtížně odlišitelná byla vrba laponská, kapradinová vegetace s paprčkou horskou a vřes obecný.

Rozšíření bezkolence modrého a třtiny křovištní, dvou rodů travin typických pro krkonošskou tundru, zkoumala Marcinkowska-Ochtyra et al. (2018a.) v jiné oblasti, a to polské chráněné oblasti Natura 2000 Jawzorna. K identifikaci expanzivních travin, které se stávají dominantní a limitují druhovou diverzitu, bylo využito kombinace HS dat s prostorovým rozlišením 1 m a leteckých LiDARových dat s průměrnou hustotou 7 bodů na m². Terénní sběr dat probíhal od pozdního jara po brzký podzim paralelně s akvizicí dat dálkového průzkumu. U HS snímků proběhla geometrická a atmosférická korekce, transformace MNF a výpočet vegetačních indexů. Na základě LiDAR bodového mračka byl odvozen CHM, parametry vegetační struktury diskrétní i fullwaveform a topografické indexy. Klasifikace proběhla metodou RF pro každý druh zvlášť. Kromě samotného rozšíření bylo cílem najít vhodné období k detekci travin, kdy se nejvíce liší jejich spektrální vlastnosti od okolní vegetace a optimální kombinaci dat. Bezkolence modrá dosáhl nejvyšší hodnoty mediánu kappa indexu 0,85 a hodnoty F1 skóre 0,89 (harmonický průměr uživatelské a zpracovatelské přesnosti počítaný iterativně) v červenci a třtina křovištní 0,65 mediánu kappa indexu a 0,73 F1 skóre v září. V případě kombinace HS dat s diskrétními nebo fullwaveform LiDARovými daty bylo vždy dosaženo vyšší přesnosti klasifikace. Zapojení LiDARu se ukázalo jako vhodný předpoklad ke zlepšení odlišení travních společenstev.

3. DATA A METODIKA

3.1. Oblast zájmu

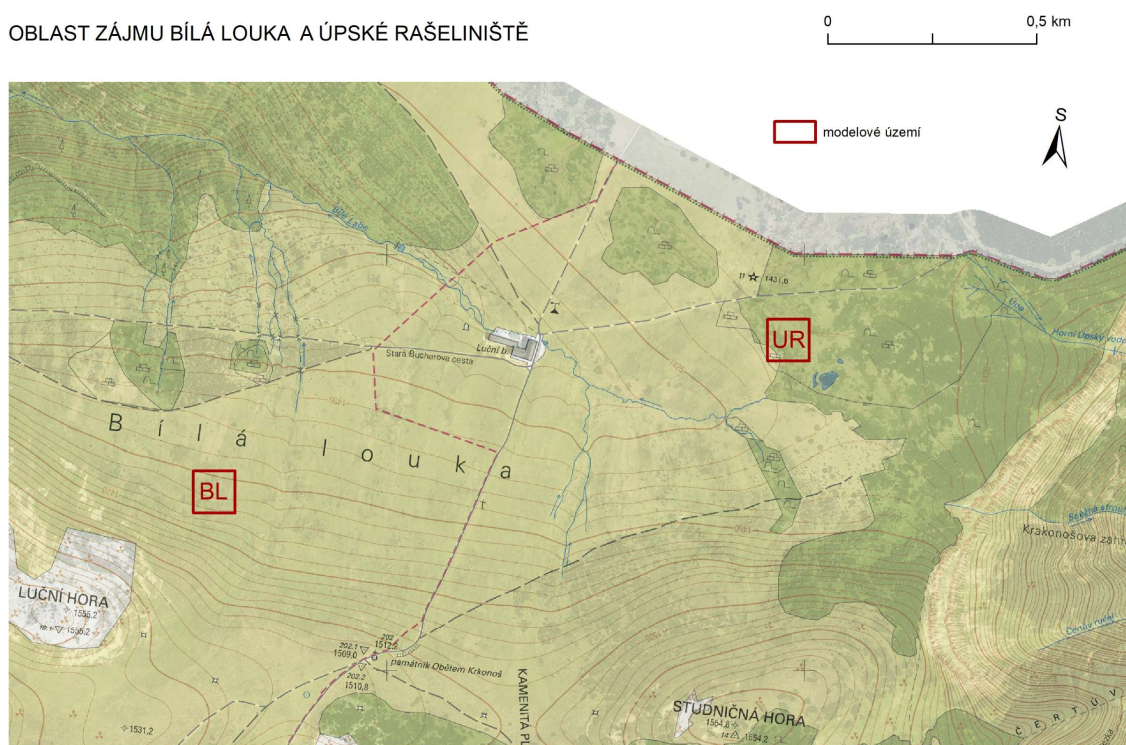
V období 2019–2023 probíhá projekt „Vegetace krkonošské tundry – minulost, současnost a budoucnost“. Hlavním cílem je popsat dosavadní změny vegetace krkonošské tundry, zmapovat současný stav porostů, kategorizovat jejich ochrannou hodnotu a stupeň ohrožení a na základě těchto informací navrhnout trvale udržitelný způsob monitoringu tundrové vegetace do budoucna s koordinovaným využitím klasických terénních metod a metod dálkového průzkumu Země. (Správa KRNP, 2021b.).

V rámci projektu dochází k vývoji metod pro sledování změn vegetace krkonošské tundry analýzou dat z MS, HS a LiDAR senzorů UAV. Snímání probíhá v oblasti Bílé louky, Luční hory, Úpského rašeliniště a Karu Úpské jámy, v ideálním případě s měsíčním intervalem od června po září. Na každé lokalitě je vymezeno modelové území o přibližné rozloze 100 x 100 m².

Pro účely této práce byla vybrána modelová území Bílá louka a Úpské rašeliniště (Obr. 1).

KRKONOŠE

OBLAST ZÁJMU BÍLÁ LOUKA A ÚPSKÉ RAŠELINIŠTĚ



Mapový podklad – ZM10, 2021 © ČÚZK; Ortofoto, 2021 © ČÚZK

Obr. 1: Zájmové území (Zdroj: vlastní zpracování)

Krkonoše se rozkládají v severovýchodních Čechách s přesahem do Polska. Jedná se o naše nejvyšší pohoří s vrcholem Sněžka (1603 m n. m.). V roce 1952 byl na polské straně vyhlášen *Karkonoski Park Narodowy* a v roce 1963 byl na české straně vyhlášen KRNAP. Obě vybraná modelová území patří ve smyslu novely (č. 123/2017 Sb.) zákona o ochraně přírody a krajiny (114/1992 Sb.) do zóny A – přírodní. Zonace rozděluje celé území národního parku podle cílů ochrany přírodních hodnot na zónu přírodní, přírodě blízkou a zónu soustředěné péče o přírodu a kulturní krajiny. V přírodní zóně je snaha zachovat původní přirozené ekosystémy a umožnit v nich nerušený průběh. Zahrnuje především unikátní ekosystémy krkonošské arкто-alpínské tundry, a to azonální stanoviště, ledovcové kary, klečové porosty, hřebenová subarktická rašeliniště, subalpínské a alpínské trávníky, mozaiky trávníků a klečových porostů, lokality jedinečných geomorfologických a geologických útvarů a významné lokality výskytu zvláště chráněných rostlin a živočichů. Zonace neupravuje volný pohyb osob, ten je na daných plochách omezen vyhlášením klidového území. Je zde umožněn pohyb pouze po vyznačených turistických trasách. (Správa KRNAP, 2019)

Existence arкто-alpínské tundry činí z Krkonoš výjimečný ostrov severské a vysokohorské přírody uprostřed Evropy (Správa KRNAP, 2021a.). Biom tundry zabírá celosvětově 2,3 % rozlohy všech suchozemských biomů. Polární tundra je rozšířena cirkumpolárně ve vyšších zeměpisných šířkách na území Severní Ameriky, Eurasie a roztroušeně v antarktické oblasti. Typická pro ni je celoroční průměrná teplota pod bodem mrazu a výskyt permafrostu. Alpínská tundra pokrývá hřebeny vysokých pohoří na obou polokoulích, vyskytuje se zde alpínský permafrost. Zásadní rozdíly mezi polární a alpínskou tundrou způsobuje roční versus denní rytmus života. Společným znakem pro oba typy tundry je bezlesé území a vikarizace (příbuzní živočichové či rostliny se v různých zeměpisných oblastech nahrazují). V místě, kde dochází k průniku obou typů tundry lze charakterizovat tundru arкто-alpínskou. Krkonoše jako nejseverněji položený horský val ve střední Evropě slouží jako spojovací článek se severskou přírodou. Během pleistocenního zalednění zasahoval do blízkosti severního úpatí Krkonoš skandinávský ledovcový štít, což způsobilo ochlazení klimatu a průnik polární tundry. Z druhé strany ze zaledněných Alp na naše území pronikala alpínská tundra. Když v holocénu přišlo oteplení, z nikdy nezaledněných krkonošských hřebenů se stal samostatný ostrov bezlesé krajiny, kde se nacházely reliktní severské a alpínské druhy. Izolovanost od okolních vysokých pohoří způsobila specifické mikroevoluční procesy (teorie ostrovní biogeografie) a vedla ke vzniku nových endemických druhů. (Štursa, 2013)

Vzácná arкто-alpínská tundra zabírá jen 7,4 % z celkové rozlohy Krkonoš. Soukupová et al. (1995) detailně rozdělila různorodé prostředí na tři zóny. Zóna kryo-eolická (lišejníková) zahrnuje nejvyšší vrcholky Krkonoš s mělkými kamenitými půdami, jmenovitě Sněžku, Obří hřeben, Luční a Studniční horu, Malý Šišák, Stříbrný hřbet a Vysoké kolo. Jedná se o oblasti dlouhodobě vystavené větru a mrazu, čímž vznikají útvary jako kryoplanační terasy, kamenná moře a různé typy mrazových a soliflukčních půdních forem. Z botanického hlediska lze zmínit výskyt severských a alpínských

mechorostů. Zóna kryo-vegetační (travnatá tundra) se nachází v okolí Luční a Labské boudy, panují zde mírnější větrné podmínky s vysokým množstvím sněhových a dešťových srážek. Mírně svažité pláně jsou pokryty mozaikou alpínských trávníků, kleče a severských strukturovaných rašelinišť. Borovice kleč (*Pinus mugo*) severněji v Evropě neroste, reliktní ostružiník moruška (*Rubus chamaemorus*) zde tvoří jižní hranici rozšíření. Mezi další reliktní druhy lze zařadit ostřici Biegelowovu (*Carex bigelowii*), rašelinič Lindbergův (*Sphagnum lindbergii*). Do niveo-glacigenní zóny (květnatá tundra) patří oblasti ledovcových karů, sněhové prohlubně, nivační deprese a svahy s letními sněhovými poli. Skládá se z pestré mozaiky ekosystémů a patří do ní krkonošské botanické zahrádky. Vyskytují se zde druhy zařazené na Červeném seznamu ohrožených cévnatých druhů České republiky: řeřišnice rýtolistá (*Cardamine resedifolia*), ostřice skalní (*Cardamine rupestris*), jinořadec kadeřavý (*Cryptogramma crista*), vrba dvoubarvá (*Salix bicolor*), vrba bylinná (*Salix herbacea*) a vrba laponská (*Salix lapponum*).

Důležité je zmínit vliv, který měl člověk v průběhu let na zdejší krajinu. Již ve 13. století vznikaly první zemské cesty a stavěly se boudy. V 17. století byla založena Luční bouda a začalo se hospodařit v její blízkosti. Odstraňovány byly porosty kleče, což způsobilo, že na některých místech došlo k antropogennímu snižování alpínské hranice lesa. Některá travní společenstva byla kosena, hnojena, choval se dobytek. Z 18. století pochází zmínka o více než 40 boudách nad 1100 m n. m. V 19. a 20. století došlo k umělé výsadbě kleče, následky výsadby jsou řešeny do dnešního dne. Na hřebenech byla v letech 1936–1939 vybudována obranná linie řopíků, zákopů a střeleckých průseků, Při vzniku státní hranice byl vykácen široký hraniční pruh. V době nedávné zaznamenala intenzivní rozvoj turistika a později i rekreace. To vše se dnes projevuje v prostorovém a druhovém složení vegetace krkonošské tundry. (Kociánová a Štursa, 2015)

3.1.1. Bílá louka

Bílá louka se rozprostírá severně mezi Luční a Studniční horou. Je pokryta druhově chudými acidofilními alpínskými travními porosty s dominantní smilkou tuhou. Smilkové louky, obrazně označované jako „hercynská poušť“, z biogeografického hlediska představují spojovací článek mezi pohořími střední nadmořské výšky, alpskými, karpatskými a severskými horskými trávníky (Štursa, 2013). Hustší a kompaktní plochy tvoří bezkolenec modrý a třtina chloupkatá. Vyšší porosty jsou zastoupeny solitérními stromy smrku ztepilého a borovice kleče.

Zkratka	Latinský název	Legenda	Hrubá legenda
afs	<i>Avenella flexuosa</i> , <i>Anthoxanthum alpinum</i> , <i>Carex bigelowii</i>	metlička křivolaká, tomka alpská, ostřice Bigelowova	alpínské trávníky zapojené /vyfoukávané alpínské trávníky
cv	<i>Calamagrostis villosa</i>	třtina chloupkatá	třtina chloupkatá
cxbig	<i>Carex bigelowii</i>	ostřice Bigelowova	alpínské trávníky zapojené /vyfoukávané alpínské trávníky
desch	<i>Deschampsia cespitosa</i>	metlice trsnatá	metlice trsnatá
mol	<i>Molinia caerulea</i>	bezkolenec modrý	bezkolenec modrý
nard	<i>Nardus stricta</i>	smilka tuhá	smilka tuhá
smrk	<i>Picea abies</i>	smrk ztepilý	dřeviny

Tab. 3: Druhy vegetace vyskytující se v modelovém území Bílá louka (klasifikační legenda).




Obr. 2: Modelové území Bílá louka, vlevo – RGB kompozit; vpravo – pohled z úbočí Luční hory. (Zdroj: KRNAP; vlastní)

3.1.2. Úpské rašeliniště

Úpské rašeliniště se nachází na obou stranách státní hranice na náhorní plošině východně od Luční boudy. Pramení zde Bílé Labe a Úpa v nadmořské výšce přes 1400 m n. m. Svým uspořádáním a přírodními poměry je velice podobné rašeliništím severní Evropy (Správa KRNAP, 2021a.). Jedná se o mozaiku vyvýšenin s dominantním suchopýrem pochvatým, suchopýrkem trsnatým, směsí vlochyně bahenní, vřesu obecného a sníženin vyplněných vodou a ostřicí bažinnou, zobánkatou, suchopýrem úzkolistým. Vlhčí části mají dobře vyvinutou mechovou vrstvu. Vyšší porosty tvoří borovice kleč.

Zkratka	Latinský název	Legenda	Hrubá legenda
cxlim	<i>Carex limosa</i>	ostřice bažinná	mokřady a rašeliniště
erang	<i>Eriophorum angustifolium</i>	suchopýr úzkolistý	mokřady a rašeliniště
ervag	<i>Eriophorum vaginatum</i>	suchopýr pochvatý	mokřady a rašeliniště
junc	<i>Juncus filiformis</i>	sítina niťovitá	mokřady a rašeliniště
klec	<i>Pinus mugo</i>	borovice kleč	kosodřevina
mol	<i>Molinia caerulea</i>	bezkoleneček modrý	bezkoleneček modrý
nard	<i>Nardus stricta</i>	smilka tuhá	smilka tuhá
ras	<i>Sphagnum sp., Drosera rotundifolia</i>	rašeliník, rosnatka okrouhlostá	mokřady a rašeliniště
rostr	<i>Carex rostrata</i>	ostřice zobánkatá	mokřady a rašeliniště
smrk	<i>Picea abies</i>	smrk ztepilý	dřeviny
ten	<i>T. cespitosum, E. vaginatum</i>	suchopýrek trsnatý, suchopýr pochvatý	mokřady a rašeliniště
trich	<i>Trichophorum cespitosum</i>	suchopýrek trsnatý	mokřady a rašeliniště
vaculig	<i>Vaccinium uliginosum</i>	vlochyně bahenní	subalpínská brusnicová vegetace
voda	<i>Aqua</i>	vodní hladina	vodní plochy
vres	<i>Calluna vulgaris</i>	vřes obecný	alpínská vřesoviště

Tab. 4: Druhy vegetace vyskytující se v modelovém území Úpské rašeliniště (klasifikační legenda).



Obr. 3: Modelové území Úpské rašeliniště, vlevo – RGB kompozit; vpravo – pohled ze středu. (Zdroj: KRNAP; vlastní)

3.2. Terénní data

Klasifikační legenda pro jednotlivá území byla vytvořena v roce 2019 a upravena v roce 2020 pracovníky z Botanického ústavu AV ČR (Akademie věd České republiky) na základě výzkumu v terénu. Došlo k určení 34 vegetačních tříd, vzniklo 1535 polygonů porostu, jejichž pozice byla určena pomocí GNSS a ortofota, o rozloze 1055,25 m² pro Bílou louku a 1265,90 m² pro Úpské rašeliniště.

Pro tři nejvíce dominantní druhy vegetace na Bíle louce, smilku tuhou, třtinu chloupkatou a bezkolonec modrý, byla navíc autorem práce měřena výška vegetace a sušiny pomocí pásma a poloha zaměřena GNSS/RTK (*Real Time Kinematic*). Měření probíhalo v červenci 2020, pro každý druh byly identifikovány dvě plochy s homogenním porostem a přibližně s půlmetrovým rozestupem bylo celkem zaznamenáno 322 bodů.

3.3. Pořízení a předzpracování LiDARových dat


Data byla pořízena bezpilotním leteckým senzorem RIEGL miniVUX-1UAV umístěném na dronu DJI Matrice 600 Pro. LiDAR senzor má udávanou absolutní přesnost určení délky průvodiče paprsku 15 mm (relativní přesnost, tj. reprodukovatelnost měření, pak 10 mm), zorné pole až 360° a zvládne provést 100 000 měření za sekundu (Riegl Laser Measurement Systems, 2021). Snímání probíhalo v termínech 16.6., 14.7., 13.8. a 9.9.2020. S ohledem na počasí byla snaha zachovat měsíční interval a obdobný termín jako v roce předchozím.

Výpočet zpřesněných trajektorií skeneru z GNSS a IMU záznamů byl proveden v softwaru PosPac. Pro GNSS korekce byla využita služba CZEPOS (Síť permanentních stanic GNSS České republiky). V softwaru RiProcess byly spočítány souřadnice bodů bodového mračna v geocentrických souřadnicích XYZ/ETRS89 (Evropský terestrický referenční systém 1989). Bodová mračna byla rozřezána podle trajektorií do jednotlivých pásů. Ty byly slícovány s využitím funkce vyrovnání bodového mračna. Princip této funkce spočívá ve vygenerování rovinných ploch v jednotlivých pásích a následné minimalizaci vzdálenosti mezi dílčími rovinami. Neznámými parametry ve vyrovnání jsou posuny a rotace jednotlivých pásů. Směrodatná odchylka vzdálenosti mezi rovinami dosahuje po vyrovnání do 0,04 m, přičemž maximální odchylky v 90 % nepřesahují 0,10 m. Bodová mračna byla vyexportována v souřadnicovém systému UTM (*Universal Transverse Mercator*)/WGS84, zóna 33 a následně převedena do S-JSTSK a výškového systému Bpv (Balt po vyrovnání) v softwaru ETJTZU poskytnutého Zeměměřickým úřadem. Výškové rozdíly ke geodeticky zaměřeným vřícovacím bodům (VLB) jsou uvedeny v Tab. 5.

Termín snímání v roce 2020				
Medián výškových rozdílů $dh = h_{GNSS} - h_{LIDAR}$ [m]				
	16.6.	14.7.	13.8.	9.9.
Bílá louka	-0,14	-0,11	-0,14	-0,02
Úpské rašeliniště	-0,09	-0,09	0,10	-0,04
Směrodatná odchylka výškových rozdílů $dh = h_{GNSS} - h_{LIDAR}$ [m]				
Bílá louka	0,03	0,04	0,03	0,02
Úpské rašeliniště	0,02	0,04	0,03	0,03

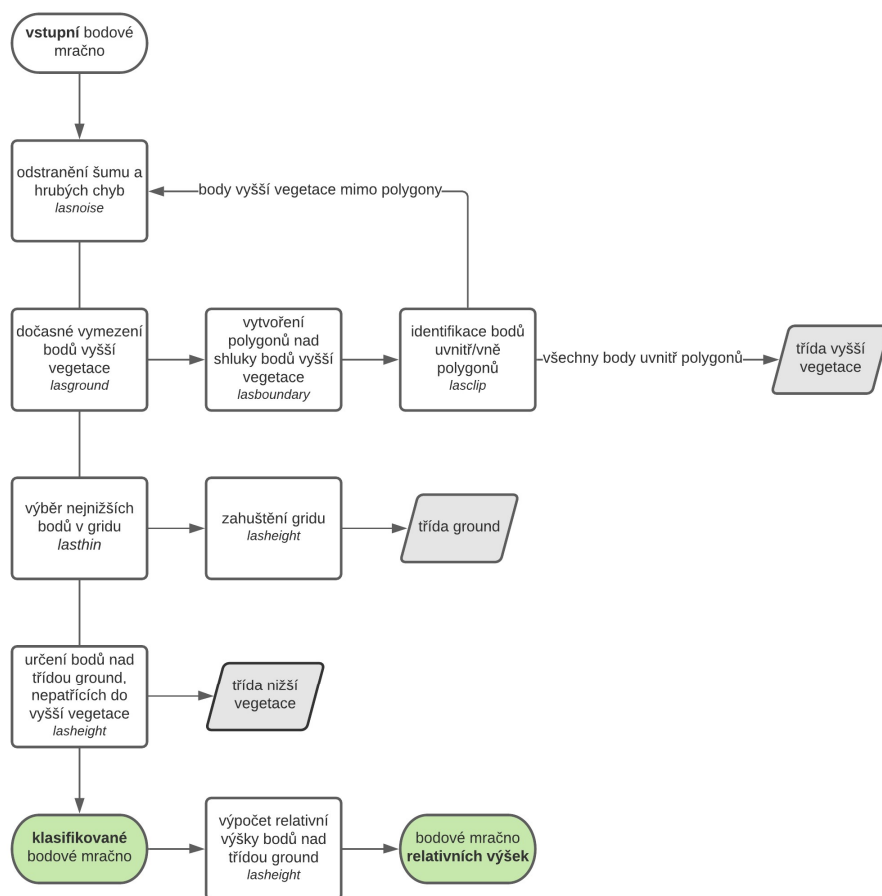
Tab. 5: Medián a směrodatná odchylka rozdílů ve výšce kontrolních bodů měřených GNSS a určených z LiDARového snímání (viz Příloha 1).

Polohová přesnost bodového mračka se obvykle hodnotí na vygenerovaných hranách např. stavebních objektů. Jelikož kontrola nad takovými objekty není v zájmových územích Bílé louky a Úpského rašeliniště možná, bylo provedeno vizuální porovnání bodového mračka s ortofotem z UAV mapování prováděného v rámci projektu v týchž časových horizontech jako LiDARové snímání v např. místech porostů kosodřeviny a jiných struktur, jak ukazuje Obr. 4. Určitelný posun bodových mračen nebyl zaznamenán.



Obr. 4: Příklad vizuální kontroly polohové přesnosti bodového mračka nad ortofotem z UAV mapování 2020 v oblasti Úpského rašeliniště.


Následující příprava dat, která byla prováděna autorem práce, je vztažena k modelovému území Bílá louka. Úpravy bodového mračka probíhaly v softwaru LAStools, vizuální kontrola výsledků a ladění parametrů v ArcGIS a CloudCompare. Cílem předzpracování LiDARových dat byla klasifikace do tří základních tříd dle výšky porostu: třída *ground* reprezentující reliéf, případně laserovým paprskem dosaženou nejspodnější část vegetace; třída nižší vegetace; třída vyšší vegetace. Výstup tvořily soubory *.las pro všechny čtyři termíny. Z daného bodového mračka následně mohla být odvozena relativní výška bodů, jež posloužila jako vstup do další analýzy. Pracovní postup je znázorněn na Obr. 5.



Obr. 5: Schéma předzpracování LiDARových dat v softwaru LASTools.

Před započítáním klasifikace byl odstraněn šum a hrubé chyby filtrací bodů, které ve svém okolí o stanovené velikosti 3 x 3 buněk, kde jedna buňka má rozměr 4 x 4 x 1 m³, měly minimální množství nebo žádné další body. Dočasně byly vymezeny body vyšší vegetace, které se nacházely minimálně 0,2 m nad nejnižšími body okolí v kroku 1 m. Nad shluky bodů vyšší vegetace byly vytvořeny polygony, které následně byly vizuálně zkontrolovány a porovnány s ortofoto snímkem. Polygony, které nerepresentovaly smrky nebo kleč byly manuálně vymazány. Všem bodům, které se při průmětu na rovinu nacházely uvnitř polygonu, byla přiřazena třída vyšší vegetace. Zbylé dočasně klasifikované body jako vyšší vegetace, které se nenacházely v žádném polygonu, byly klasifikovány jako šum a odstraněny. Z dosud nepřirazených bodů byly vybrány nejnižší body v gridu s krokem 0,5 m, a těm byla přiřazena třída *ground*. Prostorové rozlišení gridu bylo stanoveno na základě analýzy dvou hodnot 0,25 a 0,5 m. Vizuálním porovnáním a vytvořením rozdílového rastru mezi oběma hodnotami gridu bylo zjištěno, že v případě rozlišení 0,5 m je lépe zachována struktura reliéfu a dochází k menšímu nadhodnocení (zahrnutí vyšších bodů). Průměrný výškový rozdíl činil 1 cm, směrodatná odchylka 1,5 cm a maximální rozdíl 10 cm. Následně došlo k zahuštění gridu tím, že do třídy *ground* byly přiřazeny všechny body, které se nacházely do 2 cm nad nejnižšími body. Zde byl znovu zkoumán vliv nastavení daného parametru. Další uvažovanou hodnotou bylo 5 cm. Do třídy *ground* by bylo v tomto případě přiřazeno necelých 30 % z celkového

počtu bodů a došlo by k výraznějšímu nadhodnocení reliéfu, což je nežádoucí jev. Všechny zbylé body, kterým dosud nebyla přiřazena třída, tedy ty, které se nacházely více než 2 cm nad nejnižšími body a zároveň se nejednalo o vyšší vegetaci, byly klasifikovány jako nižší vegetace. Procentuální zastoupení jednotlivých tříd pro měsíc červen činilo 88,17 % bodů nižší vegetace, 11,53 % bodů *ground*, 0,3 % vyšší vegetace. Bodové mračno bylo opraveno o zjištěný výškový systematický posun, odečtením či přičtením mediánu výškových rozdílů VLB od výšky všech bodů. Následně nad klasifikovaným bodovým mračnem mohla být vypočtena relativní výška vegetace jako rozdíl mezi výškou bodu vegetace a třídy *ground* v červnu, která posloužila jako referenční pro všechny termíny. Třídě *ground* a bodům se zápornou relativní výškou byla přiřazena výška 0 m. Vertikální profil klasifikovaného bodového mračna a relativní výšky ukazuje Obr. 6.



Obr. 6: Vertikální profil bodového mračna, vlevo – klasifikace do tříd *ground* (hnědá), nižší vegetace (světle zelená), vyšší vegetace (tmavě zelená); vpravo – relativní výšky.

Data pro Úpské rašeliniště byla poskytnuta již jako bodová mračna klasifikovaná obsahující i relativní výšky. Postup předzpracování a použité hodnoty volitelných parametrů se částečně lišily s ohledem na rozdílný charakter území.

3.3.1. Hodnocení kvality dat

V průběhu zpracování dat pro Bílou louku byly zkoumány různé aspekty kvality dat pro ověření dosažených výsledků, a to slícování jednotlivých skenovaných pásů, výškový posun mezi termíny, porovnání bodů určených jako *ground* mezi termíny a přesnost relativních výšek vegetace odvozených z LiDARu.

Prvním aspektem byla přesnost slícování pásů poskytnutých LiDARových dat, která byla hodnocena v oblasti průniku všech pásů. V softwaru CloudCompare byla počítána vzdálenost a směrodatná odchylka bodů porovnávaného pásma bodového mračna k lokální aproximaci povrchu pásma referenčního bodového mračna. Použita byla metoda aproximace pomocí kvadratické funkce s nastavením šesti nejbližších sousedů a případně jejich maximální vzdálenosti 0,5 m.

Po klasifikaci bodových mračen došlo k srovnání bodů identifikovaných jako třída *ground* mezi jednotlivými termíny. Z bodů byly vytvořeny rastry nejnižších hodnot s prostorovým rozlišením 0,5 m. V ideálním případě by rastry měly odpovídat pouze reliéfu a nabývat stejných hodnot. Vzhledem k hustému pokryvu nepropustnými travními společenstvími a sušinou to nebylo předpokládáno. Rastr z června, kdy je vegetace nejméně vyvinutá, posloužil jako referenční a od něho byly odečítány rastry ze zbylých měsíců.

Relativní výšky vegetace odvozené z LiDARových dat byly validovány oproti měření prováděnému v terénu. Na GNSS/RTK zaměřených kontrolních bodech se známou výškou vegetace a sušiny byla vypočtena nová výška vegetace odečtením výšky sušiny od výšky vegetace. Tato výška následně byla porovnávána s maximální výškou vegetace v daném místě odvozeny z LiDARových dat.

3.4. Multispektrální data a digitální model povrchu

MS data poskytnutá Správou KRNAP byla pořízena skenerem Micasense RedEdge – M se spektrálními pásmy B, G, R, Red Edge, NIR a RGB kamerou Sony A7 ILCE 24,3 Mpx s objektivem Voigtlander Color – Skopar 21 mm. Obě zařízení byla připevněna na dronu DJI Matrice 600 Pro. Snímání probíhalo v termínech 17.6., 23.7., 9.9. a 10.11.2020. Modelová území byla snímána postupně v paralelních liniích v přibližně výšce 50 m nad zemským povrchem. Podélný a příčný překryv činil 85 %; u senzoru Micasense podélný překryv dosahoval pouze 65 %. Pro georeferencování snímků byly v rozích území černobílými terči signalizovány VLB o rozměru 30 x 30 cm. V okraji území byly navíc umístěny kalibrační panely pro radiometrickou korekci dat Micasense.

Předzpracování MS dat proběhlo v softwaru Agisoft Metashape. Radiometrická korekce byla založena na automatické detekci panelů ve snímku a fotografiích z terénu a následném výpočtu kalibračních koeficientů. Při geometrické korekci byla známá poloha VLB, která byla zaměřena geodetickým GNSS systémem se střední chybou 0,8 cm. VLB byly identifikovány ve všech RGB snímcích. Byly vypočteny prvky vnitřní a vnější orientace s výslednou střední chybou na VLB do 5 cm. Z překrývajících se RGB snímků bylo generováno husté bodové mračno a polygonová síť reprezentující DMP. Poskytnutým výstupem byly zvláště ortomozaiky z jednotlivých měsíců pro RGB a MS data s prostorovým rozlišením 2 cm a DMP s prostorovým rozlišením 5 cm v rastrovém formátu. Všechny rastrové výstupy byly v souřadnicovém systému S-JTSK Křovák East North, DMP pak ve výškovém systému Bpv.

3.5. Metodika


3.5.1. Výběr a výpočet strukturních parametrů vegetace

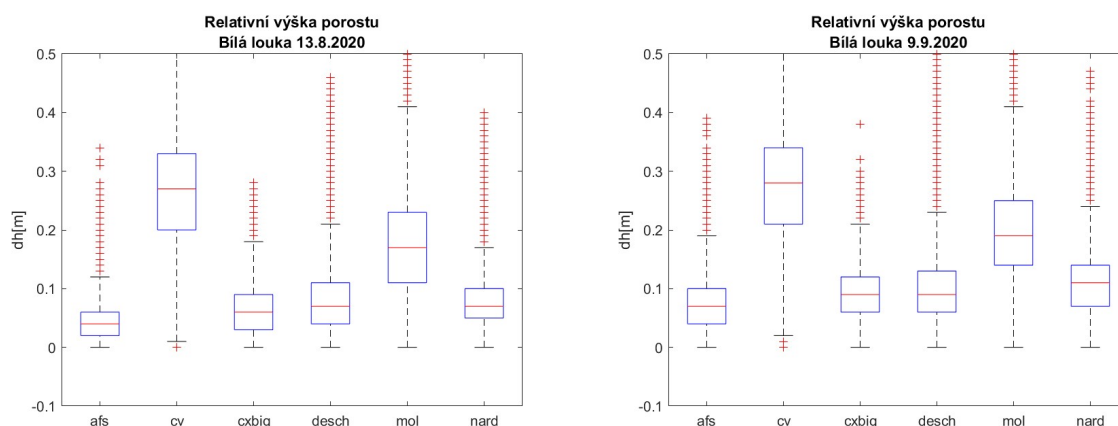
Na základě rešerše literatury bylo zvoleno 18 strukturních parametrů vegetace (Příloha 2). Dané statistiky byly vypočteny pro každou třídu vegetace zvlášť nad všemi body mračna relativních výšek spadajících do polygonů získaných terénním mapováním. Hodnoty statistik pro jednotlivé měsíce a druhy vegetace jsou pro Bílou louku uvedeny v grafické podobě v Příloze 3. Vizuálně byly také znázorněny boxploty relativních výšek porostu (Obr. 7), které podávají základní informaci o vertikální struktuře vegetace. Zhodnocením těchto výstupů bylo z původního počtu vybráno 9 strukturních parametrů, které byly určeny pro další analýzu a klasifikaci druhů vegetace. Znázorněny jsou v Tab. 6. Pro ně byla vypočtena korelační matice a provedena PCA.

Parametr	Výpočet	Zkratka
Canopy relief ratio	$(AVG - MIN) / RANGE$	CRR
Variační koeficient	STD / AVG	CV
Maximální výška	$\max \{Hrel_i\}$	MAX
Minimální výška	$\min \{Hrel_i\}$	MIN
Průměr výšek	$\Sigma Hrel_i / n$	MEAN
Variační rozpětí	$MAX - MIN$	RANGE
Směrodatná odchylka	$\Sigma (Hrel_i - AVG)^2 / n)^{1/2}$	STD
Textura	$\Sigma (Hrel_i - AVG)^2 / n_{veg})^{1/2}$	TEXT
Hustota vegetace	n_{veg} / n	VD

Tab. 6: Vybrané strukturní parametry vegetace; $Hrel_i$ je relativní výška bodu, n je celkový počet bodů v pixelu, n_{veg} je počet bodů nižší a vyšší vegetace v pixelu. (Zdroj: Evans et al., 2009)

V softwaru LASTools byly z bodového mračna relativních výšek pro každý měsíc a území odvozeny rastry výsledných strukturních parametrů. Prostorové rozlišení rastru činilo 9 cm, v průměru do každého pixelu spadalo 7 bodů a přibližně 4 % pixelů neobsahovala žádný bod. Levý dolní roh rastru byl volen tak, aby došlo ke slícování s MS daty. Z rastrů byly podle měsíce pořízení tvořeny 9 pásmové kompozity.





Obr. 7: Relativní výška porostu jednotlivých druhů vegetace pro Bílou louku.

3.5.2. Trénování modelu Random Forest

RF je metoda strojového učení pro klasifikaci a regresi. Využívá většího množství rozhodovacích stromů, které dohromady jako soubor většinovým hlasem rozhodnou o predikci. Rozhodovací stromy jsou trénovány na náhodných vzorcích dat o určité velikosti s náhradou. To znamená že jeden vzorek může být využit i v jiném rozhodovacím stromu (*bagging with replacement*). Při větvení rozhodovacího stromu je vybíráno pouze z náhodné podmnožiny prediktorů (*feature randomness*). Tím je zaručena nízká míra korelace mezi stromy. Mezi výhody této metody patří její robustnost – stromy se v souboru navzájem chrání před individuálními chybami a klasifikátor má menší náchylnost k přetrénování. Na druhé straně je žádoucí, aby jednotlivé prediktory mezi sebou nebyly korelované. Kromě toho je metoda náročná na výpočet a malá změna v datech může výrazně vést ke změně struktury stromu. (Breiman, 2001)

Trénování klasifikačního modelu RF probíhalo postupně v Matlabu nad rastry strukturních parametrů a polygony vegetace získaných terénním mapování. Nejdříve bylo nutné vytvořit šablonu rozhodovacího stromu, následně stanovit parametry modelu a natrénovat ho na souboru rozhodovacích stromů. Při růstu stromů (*template tree*) byla zvolena metoda větvení založená na interakčním testu (*interaction-curvature*) namísto standartního algoritmu CART (*Classification and Regression Trees*), který má tendenci při větvení stromu upřednostňovat prediktory s větším počtem jedinečných hodnot. Zároveň má sníženou schopnost identifikace důležitých proměnných v přítomnosti mnoha irelevantních. Interakční test volí větvící prediktor, který minimalizuje p-hodnotu chi-square testu nezávislosti mezi každým prediktorem nebo párem prediktorů a odpovědí (Loh, 2002). Jedná se o doporučenou volbu v případě, že prediktory jsou heterogenní proměnné a cílem je hodnotit důležitost prediktorů (Mathworks, 2021). Dále byla zvolena možnost využití až 10 náhradních větvení (*surrogate*) v každém uzlu, když dataset obsahuje chybějící hodnoty některých prediktorů a pozorování. Při větvení uzlu v rozhodovacím stromu bylo vybíráno ze všech prediktorů, aby nedošlo k podhodnocení či nadhodnocení některého z prediktorů. Volenými parametry pro model RF byla metoda *bagging*, v základu byl počet rozhodovacích stromů stanoven

na 200 a maximální počet větvení byl ponechán na defaultní hodnotě $n-1$, kde n je počet instancí. Daný model neboli soubor rozhodovacích stromů (*fitcensemble*) byl trénován pro každý měsíc a území zvlášť a v rámci multitemporálního přístupu pro data a prediktory ze všech měsíců zároveň.

```
% create template tree
t = templateTree('NumVariablesToSample','all',...
    'PredictorSelection','interaction-curvature','Surrogate','on');
rng(1); % for reproducibility

% create classification model
Mdl = fitcensemble(training,'class_name','Method','Bag','NumLearningCycles',200,...
    'Learners',t);
```

Skript 1: Tvorba šablony a souboru rozhodovacích strom pro trénování modelu RF.

Z natrénovaného modelu byla odvozena hodnota prediktivní míry asociace (*predictive measure of association*), která indikuje podobnost mezi rozhodovacími pravidly, která větví pozorování. Vysoká hodnota může indikovat nežádoucí korelaci mezi prediktory. Všechna možná větvení jsou porovnávána s optimálním větvením, přičemž maximální míru asociace vykazuje nejlepší náhradní větvení (Mathworks, 2021). Zároveň došlo k výpočtu počtu úrovní neboli unikátních diskretních hodnot jednotlivých prediktorů. Číselné hodnoty byly převedené na kategorické a počet kategorií určil hodnotu úrovně.

```
% predictive measure of association
[impGain,predAssociation] = predictorImportance(Mdl);

% count number of distinct numbers (levels) for predictor
training.CRR = categorical(training.CRR);
for i=1:9
    numLevels(1,i) = numel(unique(discretize(C(:,i),0:0.01:400,'categorical')));
end
```

Skript 2: Prediktivní míra asociace a výpočet úrovní prediktorů.

3.5.3. Hodnocení důležitosti prediktorů

Nespornou výhodou RF je možnost určit důležitost jednotlivých prediktorů. Dva hlavní používané přístupy pospal Breiman (2002) a Strobl et al. (2007). První je založen na permutaci pozorování. Náhodnou permutací predikující proměnné je přerušena její vazba s výslednou proměnnou. Pokud je prediktor důležitý a výsledná proměnná by na něm byla závislá, permutace jeho hodnot by měla ovlivnit negativním způsobem chybu modelu. Pokud prediktor není důležitý, jeho permutace by měla mít minimální nebo žádný vliv na chybu modelu. Další přístup pracuje na úrovni uzlů stromů. Při větvení rozhodovacího stromu je využit vždy jeden prediktor. Vylepšení v dělicím kritériu je přisouzeno právě danému prediktoru a je akumulováno přes všechny stromy. *Gini Importance* nám pak dává informaci o váženém průměru vylepšení dělicího kritéria pro každý prediktor zvlášť a je ukazatelem jeho důležitosti.

Jako jeden způsob určení důležitosti prediktorů byla aplikována metoda permutace out-of-bag pozorování, konkrétně její implementace v Matlabu. Za předpokladu, že R je RF s počtem rozhodovacích stromů T a p je počet prediktorů v trénovacích datech. (Mathworks, 2021):

1. Pro strom $t, t=1, \dots, T$.
 - a. Identifikujeme out-of-bag pozorování a indexy predikujících proměnných, které byly větveny pro růst stromu $t, s_t \subseteq \{1, \dots, p\}$.
 - b. Odhadneme chybu out-of-bag ε_t .
 - c. Pro každou predikující proměnnou $x_j, j \in S_t$:
 - I. Náhodně permutujeme pozorování x_j .
 - II. Odhadneme chybu modelu ε_{tj} s využitím out-of-bag pozorování obsahujících permutované hodnoty x_j .
 - III. Vezmeme rozdíl $d_{tj} = \varepsilon_{tj} - \varepsilon_t$. Predikujícím proměnným nevětveným při růstu stromu t je připsán rozdíl 0.
2. Pro každou predikující proměnnou v trénovacích datech spočítáme průměr d_j a směrodatnou odchylku σ_j rozdílů ve stromech, $j = 1, \dots, p$.
3. Důležitost prediktoru stanovena na základě permutace out-of-bag pozorování pro x_j je d_j / σ_j .

```

%% analysis of predictor importance
%% predictor importance estimates by permutation
%% of out-of-bag predictor observations for random forest of classification trees

impOOB = oobPermutedPredictorImportance(Mdl);

```

Skript 3: Výpočet důležitosti prediktorů metodou permutace out-of-bag pozorování.

Vzhledem k předchozí optimalizaci rozhodovacích stromů, by důležitost prediktorů měla být nezájatá vůči počtu úrovní prediktorů, rozdílnému měřítku a případným chybějícím hodnotám. Právě zkreslení výsledků je často diskutovaným tématem při určování důležitosti prediktorů. Strobl (2008), Kazemitabar et al. (2017), Sandri a Zuccolotto (2008) zmiňují zaujatost těchto metod vůči predikujícím proměnným s větším počtem pozorování a navrhují své vlastní modifikace k vyřešení problému.

Prediktory, které nebyly určeny jako důležité, nepřináší novou informaci do modelu nebo dokonce mají negativní vliv na jeho výkonnost. Pro ověření došlo k trénování modelu RF na redukovaném počtu prediktorů, které byly určeny jako důležité. Za předpokladu, že dojde k minimálnímu snížení, stagnaci nebo zvýšení přesnosti.

```

%% grow a random forest using reduced predictor set

t_reduced = templateTree('PredictorSelection','interaction-curvature',...
    'Surrogate','on','Reproducible',true); % for reproducibility

Mdl_reduced = fitensemble(training(:,{'CRR' 'CV' 'MAX' 'TEXT' 'VD'}),...
    training.class_name,'Method','Bag','NumLearningCycles',200, ...
    'Learners',t_reduced);

```

Skript 4: Trénování modelu RF na redukovaném množství prediktorů.

3.5.4. Vynechání prediktoru a individuální výkonnost prediktoru

Další využitý způsob k hodnocení důležitosti prediktorů byla metoda vynechání prediktoru (*drop column importance*). Důležitost je počítána intuitivně na základě nevyužití daného prediktoru při trénování klasifikačního modelu a následném porovnání s celkovou přesností modelu trénovaného

na všech prediktorech. Výhodou je eliminace zkreslení pro kolineární prediktory. Metoda je však výpočetně náročná vzhledem k nutnosti trénovat model pokaždé znovu. Pro individuální výkonnost prediktoru (*individual predictor performance*) byl model trénován pro každý prediktor zvlášť a jeho individuální výkonnost byla ukazatelem důležitosti. Oba způsoby byly využity pouze při monotemporálním přístupu a byly založeny na modelu RF s parametry maximálního počtu větvení s ponechanou defaultní hodnotu $n-1$, kde n je počet instancí a počet rozhodovacích stromů byl 200.

```

%% drop column predictor importance

t = templateTree('PredictorSelection','interaction-curvature',...
    'Surrogate','on','Reproducible',true); % for reproducibility

var = {'CRR' 'CV' 'MAX' 'MIN' 'MEAN' 'RANGE' 'STD' 'TEXT' 'VD'};

for i=1:9
    if i == 1
        Mdl = fitcensemble(training(:,var(i+1:9)),...
            training.class_name,'Method','Bag','NumLearningCycles',200, ...
            'Learners',t);
    elseif i == 9
        Mdl = fitcensemble(training(:,var(1:i-1)),...
            training.class_name,'Method','Bag','NumLearningCycles',200, ...
            'Learners',t);
    else
        Mdl = fitcensemble(training(:,var([1:i-1 i+1:9])),...
            training.class_name,'Method','Bag','NumLearningCycles',200, ...
            'Learners',t);
    end

    dropcolumn_oob_error(i) = oobLoss(Mdl);
    dropcolumn_oob_score(i) = 1 - dropcolumn_oob_error(i)

end

%% individually test predictors

for i=1:9
    Mdl = fitcensemble(training(:,var(i)),...
        training.class_name,'Method','Bag','NumLearningCycles',200, ...
        'Learners',t,'\Crossval','on','KFold',5);

    accuracy(i) = 1 - kfoldLoss(Mdl);

end

```

Skript 5: Vynechání prediktoru a individuální výkonnost prediktoru.

3.5.5. Kombinace s multispektrálními daty

Prediktory neboli strukturní parametry vegetace, které byly určeny jako důležité, byly využity ke klasifikaci spolu s MS daty. Bylo zkoumáno, jaký vliv budou mít přidané strukturní parametry na výsledek klasifikace. U MS dat došlo ke spojení 5 MS pásem a 3 RGB pásem do jednoho kompozitu a převzorkování na pixel o velikosti 9 cm, aby prostorové rozlišení odpovídalo datům z LiDARu. Použita byla data z dostupných měsíců červen, červenec a září. Dalším vstupem do klasifikace byly rastry strukturních parametrů vegetace s prostorovým rozlišením 9 cm ze stejných měsíců. Využit byl multitemporální přístup, klasifikace probíhala pro data ze všech měsíců současně. Použitá legenda se nachází v části 3.1 Oblast zájmu (Tab. 3 a Tab. 4).

Polygony získané terénním měřením byly rozděleny v poměru 1:2 na trénovací a validační. Ty, které se nacházely ve stínu nebo na hranici dvou kategorií nebyly brány v potaz. Pro některé třídy byl pouze malý počet polygonů nebo jejich distribuce byla nepravidelná, rozložení však odpovídalo skutečnému výskytu dané vegetace. Pro trénování klasifikátoru byly využity všechny trénovací polygony. Jednotlivé třídy měly různý počet instancí a tak, aby nedocházelo k podhodnocování tříd s menším zastoupením na úkor tříd s větším zastoupením, byla využita matice chyb klasifikace. Matice stanoví tzv. *cost* neboli penalizaci při nesprávné predikci dané třídy. Třídám byla přiřazena váha inverzní hodnoty jejich zastoupení v trénovacích datech (Tab. 7 a Tab. 8).

Třída	Podíl v součtu trénovacích ploch	Zaokrouhleno	Inverzní poměr/váha
afs	3,73 %	5	20,3
cv	32,44 %	30	3,38
cxbig	0,94 %	1	101,5
desch	18,78 %	20	5,08
mol	29,31 %	30	3,38
nard	14,30 %	15	6,77
smrk	0,49 %	0,5	203

Tab. 7: Zastoupení tříd v trénovacích datech a vypočtené váhy pro matici chyb klasifikace pro Bílou louku.

Třída	Podíl v součtu trénovacích ploch	Zaokrouhleno	Inverzní poměr/váha
cxlim	0,97 %	1	94,5
erang	2,59 %	5	18,9
ervag	6,87 %	5	18,9
junc	0,34 %	0,5	189
klec	46,01 %	45	2,1
mol	0,58 %	0,5	189
nard	9,63 %	10	9,45
rostr	6,67 %	5	18,9
smrk	0,57 %	0,5	189
ten	11,14 %	10	9,45
trich	12,47 %	10	9,45
vaculig	0,60 %	0,5	189
voda	0,66 %	0,5	189
vres	0,90 %	1	94,5

Tab. 8: Zastoupení tříd v trénovacích datech a vypočtené váhy pro matici chyb klasifikace pro Úpské rašeliniště.

Samotná klasifikace proběhla v softwaru Matlab nejdříve samostatně pro MS data a LiDAR odvozené strukturálními parametry vegetace a poté pro jejich kombinaci. Pro algoritmus RF bylo optimalizováno nastavení parametru počtu stromů a maximálního počtu větvení.

```

% extract predictors and response

inputTable = trainingData;
predictorNames = {'MAX_06', 'MIN_06', 'MS1_06', 'MS2_06', 'MS3_06', 'MS4_06',
'MS5_06', 'MS6_06', 'MS7_06', 'MS8_06', 'MAX_07', 'MIN_07', 'MS1_07', 'MS2_07',
'MS3_07', 'MS4_07', 'MS5_07', 'MS6_07', 'MS7_07', 'MS8_07', 'MAX_09', 'MIN_09',
'MS1_09', 'MS2_09', 'MS3_09', 'MS4_09', 'MS5_09', 'MS6_09', 'MS7_09', 'MS8_09'};
predictors = inputTable(:, predictorNames);
response = inputTable.class_name;

% train classifier

template = templateTree(...
'MaxNumSplits', 5000);
classificationEnsemble = fitcensemble(...
predictors, ...
response, ...
'Method', 'Bag', ...
'NumLearningCycles', 50, ...
'Learners', template, ...
'Cost', [0 20 20 20 20 20 20 20; 3.3 0 3.3 3.3 3.3 3.3 3.3; 100 100 0 100 100 100
100; 5 5 5 0 5 5 5; 3.3 3.3 3.3 3.3 0 3.3 3.3; 6.7 6.7 6.7 6.7 6.7 0 6.7; 200 200
200 200 200 0], ...
'ClassNames', {'afs'; 'cv'; 'cxbig'; 'desch'; 'mol'; 'nard'; 'smrk'});

%% classify image

yfit = classificationEnsemble.predictFcn(MSclass);

```


Skript 6: Trénování modelu a klasifikace RF celého modelového území pro kombinaci MS a LiDARových dat.

Validace výsledků proběhla na 3393 validačních bodech pro každé modelové území. Počet validačních bodů byl určen na základě validační přesnosti na 2% hladině spolehlivosti dle Foody (2009). V rámci validačních polygonů, které nevstupovaly do klasifikace, byly generovány body stratifikované s ohledem na celkovou rozlohu tříd. Minimální počet bodů na třídu byl 50, body se nacházely v centru pixelu s minimální vzdáleností 13 cm od sebe.

3.5.6. Experimentování s digitálním modelem povrchu

Kromě LiDARových dat, ze kterých lze získat parametry výšky a struktury vegetace, obsahuje některé informace o vertikální struktuře vegetace i DMP, který tak jako tak vzniká při zpracování MS dat. Nabízí se otázka, zda by jeho zapojením do klasifikace MS dat nešlo dosáhnout obdobného výsledku jako u strukturních parametrů odvozených z LiDARu.

Jako základ pro další kroky byl využit DMP v rastrovém formátu reprezentovaný absolutními nadmořskými výškami z června, července, září a listopadu. Zpracování probíhalo v ArcMapu. Červnový DMP byl brán jako referenční a jeho odečtením od zbylých měsíců vznikly tři rozdílové rastry relativních výšek. Dané rastry znázorňují výškový rozdíl neboli nárůst či naopak snížení vegetace v daném měsíci při porovnání s její výškou v červnu a dávají nám informaci o vertikální struktuře vegetace. Došlo k převzorkování metodou průměru na prostorové rozlišení 9 cm, slícování s MS daty a spojení do tří pásmového kompozitu (Obr. 8). Následně, pro zhodnocení získaných strukturních parametrů, proběhla multitemporální klasifikace nejdříve samostatných vrstev odvozených z DMP a poté pro jejich kombinaci s MS daty. Postup klasifikace odpovídá předešlé kapitole 3.5.5 Kombinace s multispektrálními daty.



Obr. 8: Deriváty DMP z Bíle louky, vlevo – rozdílový rastr pro červen a červenec; vpravo – RGB kompozit rozdílových rastrů z července, září a listopadu.

3.5.7. Metriky pro hodnocení klasifikační přesnosti

Pro průběžné hodnocení kvality trénovaných modelů a výsledků klasifikace bylo využito následujících metrik a jejich definic:

- Out-of-bag skóre (*OOB score*) – je podíl mezi správně predikovanými out-of-bag vzorky a celkovým počtem out-of-bag vzorků, které v ideálním případě tvoří 36,8 % z trénovacích dat. Nabývá hodnot od 0 do 1, případně jej lze vyjádřit procentuálně. Vychází z *baggingu* s náhradou. Vzorek, který nebyl vybrán pro daný rozhodovací strom, se nazývá out-of-bag a následně může být predikován všemi rozhodovacími stromy ve kterých se nenachází. Na základě převažujícího hlasu je určena jeho klasifikační třída. (Bhatia, 2019)
- Celková přesnost (*overall accuracy*) – udává podíl mezi všemi správně klasifikovanými pixely a celkovým počtem klasifikovaných pixelů (Lillesand et al., 2015). Nabývá hodnot od 0 do 1, případně ji lze vyjádřit procentuálně. Může být počítána na trénovacích i validačních (testovacích) datech. V případě výpočtu na všech trénovacích datech nám dává informaci pouze o tom, jak si daný model vede na daných datech. Pokud bychom chtěli odhadnout, jak model bude fungovat na nových datech, je lépe využít některý ze způsobů validace. K-fold cross validace rozdělí trénovací data do k podmnožin stejných velikostí, každá množina je jednou použita pro testování modelu trénovaného na zbylých podmnožinách. Výsledná celková přesnost je stanovena jako průměr z k testování. Holdout validace vezme uživatelem určenou procentuální část z trénovacích dat, která nebude vstupovat do trénování a využije ji k testování modelu a výpočtu celkové přesnosti, výsledný model je poté znovu natrénován na všech datech. K validaci výsledků klasifikace se využívá celková přesnost vypočtena na validačních (testovacích) datech, která vůbec nevstupují do trénování modelu. Porovnáním přesnosti vypočtené na všech trénovacích datech a validační (testovací) přesnosti lze určit, zda nedochází k přeučení nebo nedoučení modelu. (Mathworks, 2021)

- Chybová matice (*confusion matrix*) – někdy zvaná také kontingenční tabulka nám dává na úrovni tříd informace o vztahu mezi referenčními daty a korespondujícími výsledky klasifikace. Matice je čtvercová a počet řádků a sloupců odpovídá počtu klasifikovaných tříd. V řádcích se většinou nachází klasifikovaná data a sloupce definují referenční skutečnou třídu. Pixely, které byly správně klasifikovány se nacházejí podél hlavní diagonály. Všechny ostatní hodnoty ve sloupcích znázorňují buď chyby z opomenutí nebo v řádcích chyby z nesprávného zařazení. Z chybové matice vychází uživatelská a zpracovatelská přesnost. Celkovou přesnost lze z chybové matice získat jako podíl sumy hodnot na diagonále k sumě všech hodnot. (Lillesand et al., 2015)
- Zpracovatelská přesnost (*producer's accuracy*) – indikuje pravděpodobnost, že daný pixel je správně klasifikován. Z chybové matice ji lze vyčíst jako podíl správně klasifikovaných pixelů ve třídě k celkovému počtu pixelů použitých pro testování dané třídy, tedy hodnota na diagonále k sumě hodnot ve sloupci. (Congalton a Green, 2009)
- Uživatelská přesnost (*user's accuracy*) – určuje pravděpodobnost s jakou klasifikovaný pixel skutečně reprezentuje danou třídu a jedná se o míru chyby z nesprávného zařazení. Z chybové matice jí lze vyčíst podílem správně klasifikovaných pixelů ve třídě k celkovému počtu pixelů klasifikovaných jako daná třída, tedy hodnota na diagonále k sumě hodnot v řádku. (Congalton a Green, 2009)

4. VÝSLEDKY

4.1. Bílá louka

4.1.1. Hodnocení kvality dat

U přesnosti slícování pásů poskytnutých LiDARových dat se medián průměrné vzdálenosti mezi pásmy pohyboval v rozmezí 3–5 cm, medián směrodatné odchylky 3–4 cm v závislosti na měsíci. Maximální průměrná vzdálenost pásem činila 5 cm pro červen a červenec, 6 cm pro srpen a září.

Po klasifikaci bodových mračen došlo k srovnání bodů identifikovaných jako třída *ground* mezi jednotlivými termíny. Průměrné hodnoty rozdílových rastrů a směrodatné odchylky jsou znázorněny v Tab. 9. Termín červen a červenec vykazuje shodu, v případě srpna a září je již patrná menší průchodnost laserového paprsku způsobená nárůstem vegetace. Různé hodnoty lze vizuálně pozorovat v závislosti na druhu vegetace, která dané místo pokrývá. V případě třtiny chloupkaté (*cv*), která narůstá nejvíce do výšky a tvoří v dané oblasti kompaktní porosty, dochází v pozdějších termínech k výraznějšímu nadhodnocování třídy *ground* než u bezkolence modrého (*mol*). Smilka tuhá (*nard*) je naopak nejvíce průchodná v srpnu, kdy už není slehlá po sněhu, a ještě nenarostla.

Rozdílový rastr vrstev <i>ground</i>	MEAN [m]	STD [m]
červenec - červen	-0,0052	0,043
srpen - červen	0,028	0,053
září - červen	0,047	0,055

Tab. 9: Hodnoty průměru a směrodatné odchylky pro rozdílové rastry vrstev *ground* mezi měsíci.

Relativní výšky vegetace odvozené z LiDARových dat validovány oproti měřením v terénu jsou znázorněny v Tab. 10. Průměrný rozdíl mezi naměřenými výškami činil 9 cm od sušiny a 18 cm od země. Odchylky měření výšky porostu od země nad jednu směrodatnou odchylku od průměru se vyskytly v 10 % případů s maximem 0,44 m. Pro měření výšky porostu od sušiny se odchylky nad 0,15 m vyskytly v 17 % případů s maximem 0,35 m. V rámci druhů vegetace smilka tuhá (*nard*) vykazovala menší rozdíl a směrodatnou odchylku než bezkolence modrý (*mol*) a třtina chloupkatá (*cv*). Ze znaménka průměru lze vyčíst, že dochází k podhodnocování výšek vegetace u LiDARu a to kombinací nadhodnocování terénu, laserový paprsek pravděpodobně nepronikne ani k sušině a zároveň se neodrazí od nejvyššího bodu stébla ale níže.

	MEAN [m]	STD [m]	MIN [m]
měření výšky porostu od země - červenec LiDAR	0,18	0,06	-0,03
smilka tuhá	0,15	0,04	0,08
bezkolence modrý	0,20	0,07	-0,03
třtina chloupkatá	0,19	0,06	0,02
měření výšky porostu od sušiny - červenec LiDAR	0,09	0,06	-0,10
smilka tuhá	0,07	0,04	-0,01
bezkolence modrý	0,10	0,07	-0,10
třtina chloupkatá	0,10	0,07	-0,02

Tab. 10: Porovnání výšky vegetace naměřené v terénu a odvozené z LiDARových dat.

4.1.2. Korelace a analýza hlavních komponent

Korelační matice z července (Tab. 11) ukázala, že strukturní parametry RANGE, STD a TEXT jsou silně korelované. Zároveň mají blízko k parametru MAX. Další dvojicí s vyšší hodnotou korelačního koeficientu je MEAN a MAX.

	CRR	CV	MAX	MIN	MEAN	RANGE	STD	TEXT	VD
CRR	1,00	-0,26	0,09	0,08	0,18	0,07	0,07	0,04	0,05
CV	-0,26	1,00	-0,19	-0,50	-0,30	0,08	0,13	0,09	-0,47
MAX	0,09	-0,19	1,00	0,70	0,98	0,88	0,84	0,85	0,14
MIN	0,08	-0,50	0,70	1,00	0,79	0,28	0,27	0,30	0,28
MEAN	0,18	-0,30	0,98	0,79	1,00	0,79	0,74	0,75	0,18
RANGE	0,07	0,08	0,88	0,28	0,79	1,00	0,96	0,95	0,01
STD	0,07	0,13	0,84	0,27	0,74	0,96	1,00	0,99	-0,01
TEXT	0,04	0,09	0,85	0,30	0,75	0,95	0,99	1,00	0,08
VD	0,05	-0,47	0,14	0,28	0,18	0,01	-0,01	0,08	1,00

Tab. 11: Korelační matice strukturních parametrů.

PCA je metoda redukce dimenzionality, která původní proměnné transformuje lineární kombinací do hlavních komponent při zachování většiny obsažené informace. Vlastní vektory znázorňují směr os, které nejvíce zvýrazňují rozdíly mezi pozorováními. PCA tak může napomoci identifikovat důležité strukturní parametry. Z vlastních čísel bylo vypočteno množství obsažené informace ve smyslu variance pro každou komponentu zvlášť. Pro zachování 95 % informace bylo nutné využít první čtyři komponenty, které dohromady mají 95,83 %. V Tab. 12 lze pozorovat, že MAX je důležitý především v první hlavní komponentě, která obsahuje většinu informace. V druhé hlavní komponentě převažuje CV, CRR a VD, třetí MIN a CRR a čtvrté CRR a VD. Vektory TEXT, RANGE a STD všechny směřují stejným směrem při vizuálním znázornění kombinace dvou hlavních komponent, což může indikovat korelaci mezi původními proměnnými, která byla potvrzena korelační maticí.

Hlavní komponenta	1	2	3	4
	Vlastní vektor			
CRR	-0,13	-0,42	-0,53	-0,56
CV	0,15	0,58	0,13	0,04
MAX	-0,44	0,01	0,18	-0,04
MIN	-0,27	-0,31	0,66	-0,15
MEAN	-0,43	-0,07	0,25	-0,10
STD	-0,41	0,24	-0,22	0,05
RANGE	-0,41	0,25	-0,22	0,05
TEXT	-0,41	0,24	-0,20	0,11
VD	-0,11	-0,46	-0,17	0,79
Vlastní číslo	4,93	1,99	0,97	0,73
Vysvětlená variance	54,79 %	22,12 %	10,79 %	8,13 %

Tab. 12: Vlastní vektory, vlastní čísla a vysvětlená variance pro první čtyři hlavní komponenty.

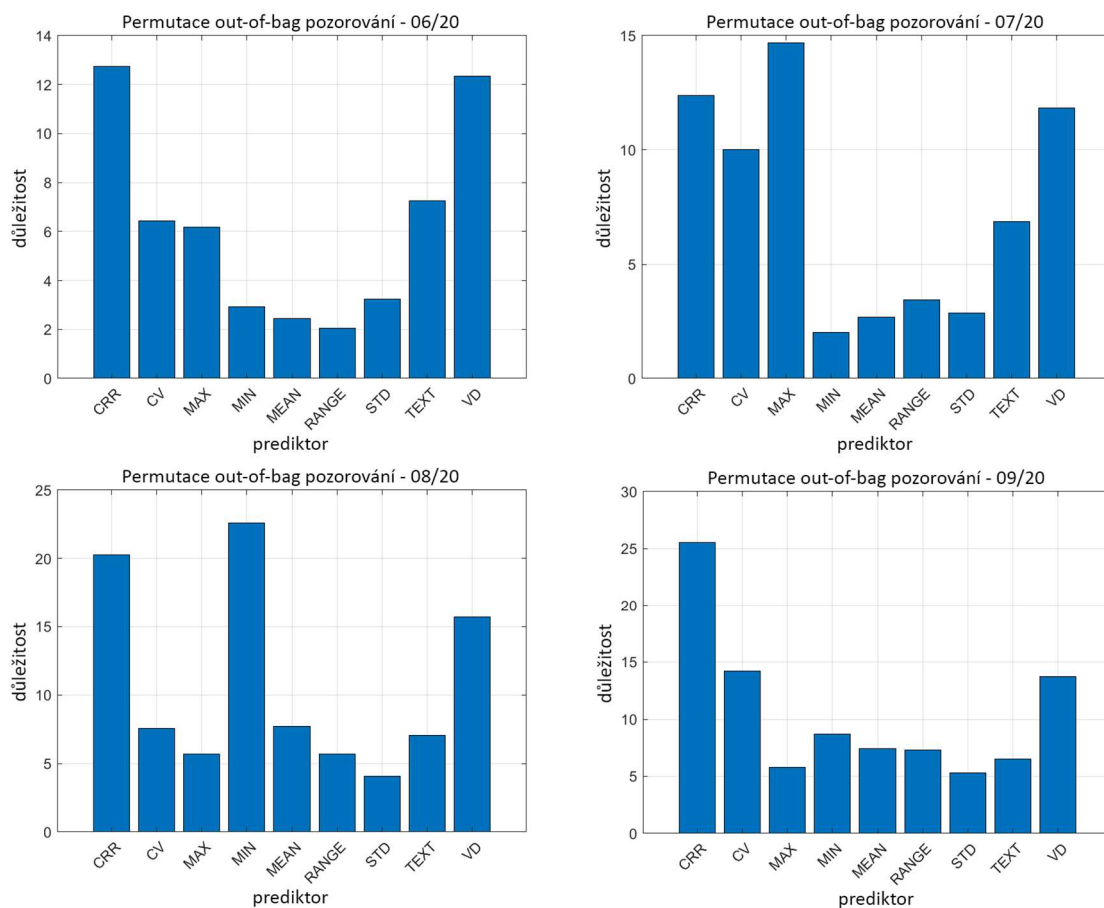
4.1.3. Důležitost prediktorů

Z hlediska počtu úrovní jednotlivých prediktorů se jedná o nevyvážený dataset. Pro každý měsíc se hodnoty mírně lišily. Oproti ostatním prediktorům měl CV výrazně více diskrétních hodnot, v srpnu a září také CRR. Úrovně ostatních prediktorů byly vyrovnané. Prediktivní míra asociace nevykazovala vysoké hodnoty, podobnost mezi rozhodovacími pravidly nebyla indikována ani v případě potencionálně korelovaných prediktorů. Grafické znázornění obou proměnných je znázorněno v Příloze 4 a 5.

Důležitost prediktorů metodou permutace out-of-bag pozorování byla určena pro každý měsíc zvlášť. Počítáno bylo OOB skóre pro model trénovaný na všech prediktorech a poté pouze na redukovaném počtu prediktorů, které byly určeny jako nadějně pro odlišení vegetace krkonošské tundry. Výsledky OOB se nachází v Tab. 13 a důležitost prediktorů je vizualizována na Obr. 9. V červnu vyšly jako nejdůležitější prediktory CRR a VD, následovány TEXT, CV a MAX. Trénováním modelu na redukovaném množství prediktorů bylo dosaženo zvýšení OOB skóre. Červenec vyzdvihl MAX a CRR s VD, těsně za nimi TEXT a CV. Trénováním modelu na redukovaném množství prediktorů bylo dosaženo minimálního snížení OOB skóre. V srpnu v porovnání s ostatními prediktory mnohem větší důležitosti dosáhl MIN, CRR a VD. Při spuštění modelu na redukovaném množství prediktorů došlo ke snížení OOB skóre o 0,07, přidáním dalšího prediktoru v pořadí MEAN byl již pokles minimální o 0,002. V září se jako nejvýznamnější projevíly prediktory CRR, CV, VD. Samostatná kombinace těchto prediktorů se ukázala jako nedostačující, vzhledem k tomu, že při trénování modelu na redukovaném množství prediktorů byl pozorován pokles OOB skóre o 0,129. Další důležitý prediktor MIN snížil pokles OOB skóre na 0,0312. Srovnatelného výsledku jako při trénování na všech prediktorech bylo dosaženo až po přidání prediktorů určených jako důležitých v červnu a červenci MAX a TEXT, poté pokles OOB skóre činil pouze 0,007.

Měsíc	06	07	08	09
	OOB skóre			
Všechny prediktory	0,4848	0,6797	0,6944	0,6898
Redukované množství prediktorů	CRR, CV, MAX, TEXT, VD 0,4858	CRR, CV, MAX, TEXT, VD 0,6794	CRR, MIN, VD 0,6828	CRR, CV, VD 0,5608
			CRR, CV, MIN, MEAN, VD 0,6926	CRR, CV, VD, MIN 0,6586
			CRR, CV, MAX, TEXT, VD 0,6950	CRR, CV, MAX, MIN, TEXT, VD 0,6826

Tab. 13: Hodnoty OOB skóre pro jednotlivé kombinace prediktorů - BL.

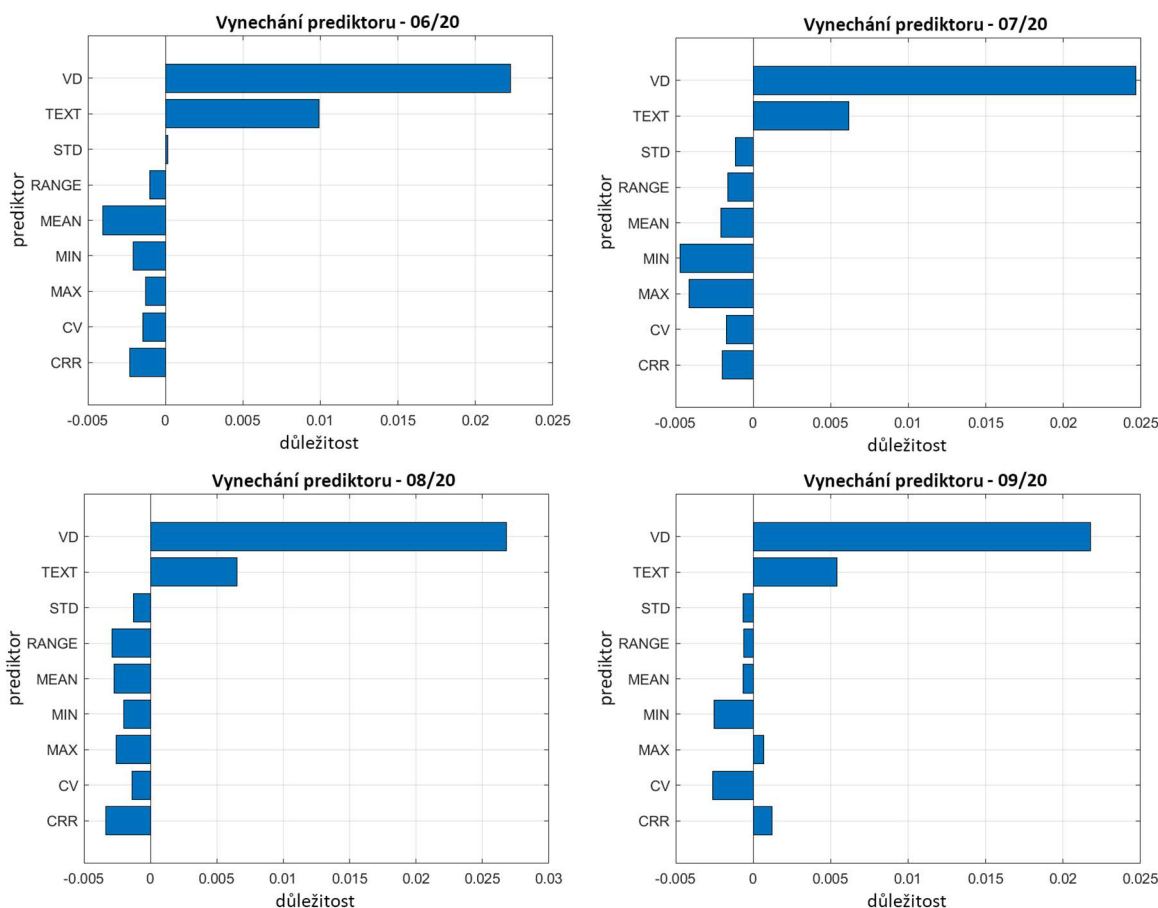


Obr. 9: Důležitost prediktorů určena metodou permutace out-of-bag pozorování - BL.

V případě vynechání prediktoru bylo pozorováno, že při odstranění většiny prediktorů dojde ke zvýšení OOB skóre o maximálně 0,5 %, z čehož nelze vyvodit závěry, protože se jedná o podprahovou hodnotu. OOB skóre se při několikanásobném spuštění trénovaného modelu na stejných datech a s totožnými parametry měnilo v rozmezí ± 1 %. Podstatné je, že při vypuštění prediktorů VD nebo TEXT došlo ve všech měsících ke snížení OOB skóre o 2 až 3 %. Jejich individuální schopnost předpovídat není pravděpodobně vysoká, ale nesou informace neobsažené v ostatních prediktorech, které mohou napomoci k lepšímu výsledku klasifikace. Pro září ještě došlo ke snížení OOB skóre u prediktorů CRR a MAX. V Tab. 14 jsou znázorněny hodnoty OOB skóre při vyřazení daného prediktoru z trénování modelu. Druhý sloupec reprezentuje OOB skóre při trénování modelu na všech prediktorech. V Obr. 10 je důležitost definována jako rozdíl mezi OOB skóre pro všechny prediktory a bez daného prediktoru. Kladná hodnota značí, že při odstranění daného prediktoru došlo ke snížení OOB skóre a tím pádem má prediktor větší důležitost. Naopak záporná hodnota poukazuje na to, že při odstranění daného prediktoru došlo ke zvýšení OOB skóre.

	VŠE	CRR	CV	MAX	MIN	MEAN	RANGE	STD	TEXT	VD
06	0,4729	0,4752	0,4743	0,4742	0,4750	0,4769	0,4739	0,4727	0,4630	0,4506
07	0,6649	0,6669	0,6666	0,6690	0,6696	0,6670	0,6665	0,6660	0,6587	0,6402
08	0,6893	0,6927	0,6907	0,6919	0,6913	0,6921	0,6922	0,6906	0,6828	0,6625
09	0,6806	0,6793	0,6832	0,6799	0,6831	0,6812	0,6812	0,6812	0,6751	0,6588

Tab. 14: Hodnoty OOB skóre při vynechání daného prediktoru - BL.



Obr. 10: Důležitost prediktorů určena na základě vynechání prediktoru - BL.

Při trénování modelu pro každý prediktor zvlášť bylo k hodnocení kvality modelu využito celkové přesnosti s využitím k-fold cross validace ($k = 5$). Z Tab. 15 je patrné, že individuální výkonnost prediktorů MAX a MIN je ve všech termínech kromě června nejvyšší a nad 50% hranicí. Nad 50 % celkové přesnosti se ještě dostal prediktor MEAN v červenci, srpnu a CV v červenci. Naopak individuálně si nejhůře vedl VD a CRR pod hranicí 40 % úspěšnosti. Ostatní prediktory se pohybovaly v rozmezí celkové přesnosti 40 a 50 %.

Měsíc	CRR	CV	MAX	MIN	MEAN	RANGE	STD	TEXT	VD
06	0,37	0,37	0,42	0,38	0,32	0,42	0,42	0,43	0,33
07	0,40	0,51	0,60	0,58	0,50	0,45	0,45	0,45	0,37
08	0,37	0,49	0,56	0,56	0,52	0,40	0,41	0,42	0,36
09	0,34	0,47	0,55	0,55	0,49	0,40	0,41	0,42	0,34

Tab. 15: Celková přesnost k-fold cross validace pro individuální prediktory - BL.

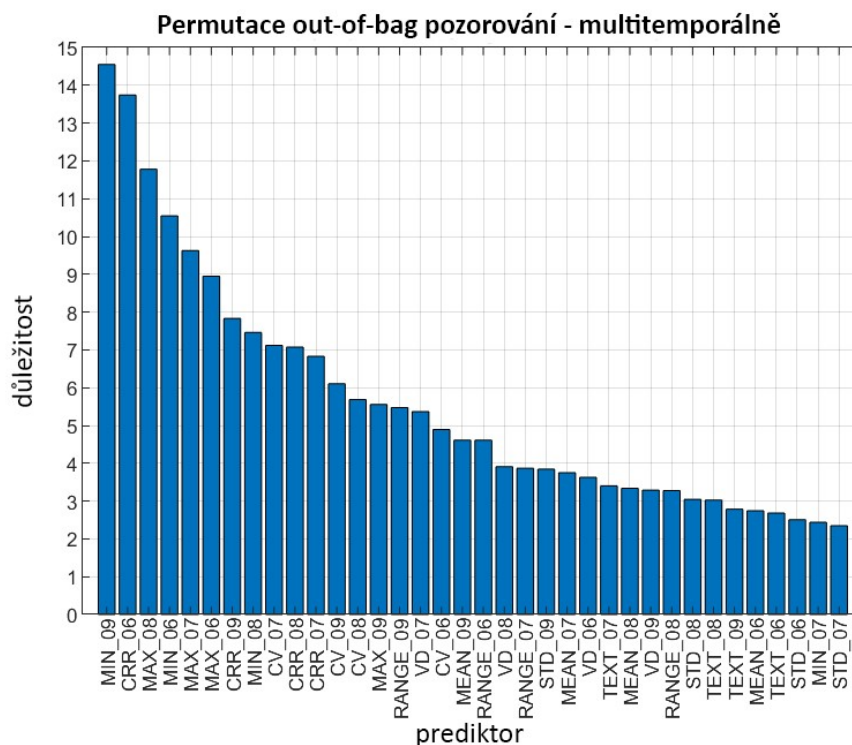
Pro hodnocení vztahu mezi prediktory a jednotlivými druhy vegetace, respektive schopnosti modelu RF se naučit dané druhy rozlišit, bylo využito chybové matice a uživatelské a zpracovatelské přesnosti z k-fold cross validace ($k = 5$) nad trénovacími daty. Červen nebyl brán v potaz vzhledem k nevyvinuté vegetaci a nepříznivým výsledkům. U ostatních měsíců se uživatelská a zpracovatelská přesnost smrku ztepilého pohybuje kolem 100 %. Třtina chloupkatá (cv) dosáhla v červenci

zpracovatelské přesnosti přes 90 %, v srpnu a září přes 80 %, nejčastěji u ní dochází k záměně za bezkolenec modrý (*mol*). Travniny bezkolenec modrý (*mol*), smilka tuhá (*nard*), metlice trsnatá (*desch*) se pohybují v rozmezí zpracovatelské přesnosti 40 až 70 % v závislosti na měsíci. Z nich nejlépe identifikovatelný je bezkolenec modrý (*mol*) s uživatelskou i zpracovatelskou přesností nad 60 %, bývá nesprávně určen jako třtina chloupkatá (*cv*) nebo metlice trsnatá (*desch*). U druhů spadajících do vyfoukaných a zapojených alpínských trávníků, ostřice Bigelowova (*cxbig*) a metlička křivolaká, tomka alpská, ostřice Bigelowova (*afs*) stoupá přesnost s postupem vegetační sezóny. Monotemporálně jsou však velice obtížně klasifikované se zpracovatelskou přesností 10 až 40 %.

4.1.4. Multitemporální přístup

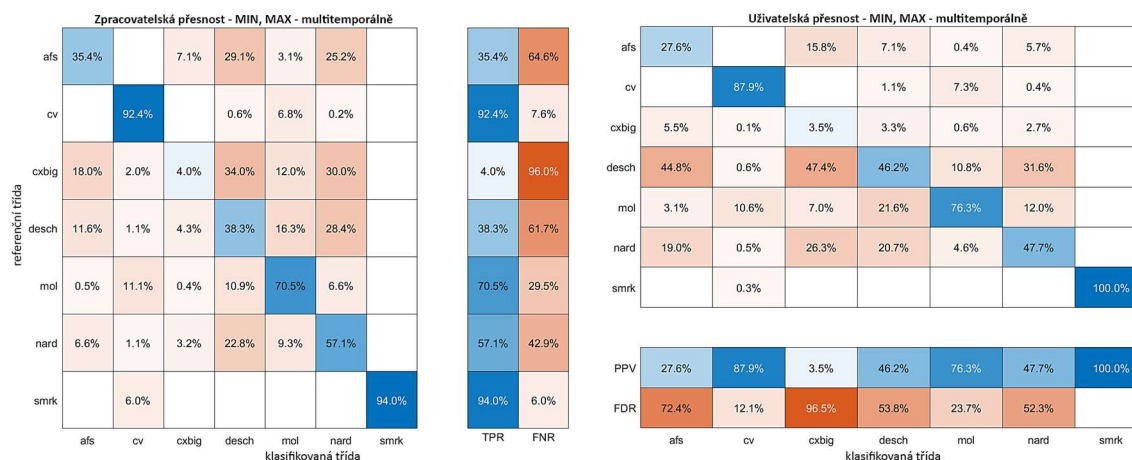
Trénování modelu a určování důležitosti prediktorů pro každý měsíc zvlášť dává naději, že strukturní parametry vegetace odvozené z LiDARových dat mají potenciál klasifikovat druhy vyskytující se v krkonošské tundře. Informace obsažená v jednom měsíci se však jeví jako nedostatečná. Proto bylo přistoupeno k multitemporálnímu přístupu. Dohromady byly smíchány všechny prediktory ze všech termínů. Změna vegetace a její struktury v čase může napomoci k lepším výsledkům.

Odhady důležitosti prediktorů (Obr. 11) byly určeny pomocí permutace out-of-bag pozorování. Prediktory MIN, MAX, CRR a CV byly v multitemporálním přístupu určeny jako významné. Jejich odhadovaná hodnota důležitosti je vyšší oproti zbylým prediktorům. Mezi 14 nejdůležitějšími prediktory, které se skládají právě jenom z MIN, MAX, CRR a CV není zastoupena pouze hodnota CV_06 a MIN_07. Z těchto prediktorů byly kromě MIN_06 všechny určeny jako důležité i v monotemporální části. Při trénování modelu na všech prediktorech bylo dosaženo OOB skóre 0,9130. Při použití pouze prediktorů MIN a MAX bylo dosaženo OOB skóre 0,9003, přidáním CRR došlo k minimálnímu zvýšení na 0,9046, přidáním CV došlo k zvýšení na 0,9078. Rozdíl v OOB skóre pro redukovaný počet prediktorů MIN a MAX činí 1,3 %. Bylo stanoveno, že kombinací daných dvou prediktorů lze v multitemporálním přístupu vysvětlit většinu odlišností mezi druhy. Pro úplnost byly zkoušeny i kombinace ostatních lépe vycházejících prediktorů: pro CRR a CV dosáhlo OOB skóre 0,7812, pro CRR a MAX 0,8801, CRR a MIN 0,8864.



Obr. 11: Důležitost prediktorů určena permutací out-of-bag pozorování – multitemporálně - BL.

Chybová matice pro model RF nad validačními daty s využitím prediktorů MIN, MAX se nachází na Obr. 12. Podává informaci o tom, jak si LiDARová data vedou pro jednotlivé druhy. Smrk ztepilý dosáhl zpracovatelské (uživatelské) přesnosti 94 (100) %. Následovala třtina chloupkatá (*cv*) s 92,4 (87,9) %, bezkolenec modrý (*mol*) 70,5 (76,3) % a smilka tuhá (*nard*) 57,1 (47,7) %. Hranici 50 % nepřesáhla metlice trsnatá (*desch*) s 38,3 (46,2) % a smíšená třtina křivolaké, tomky alpské, ostřice Bigelowové (*afsbig*) 35,4 (27,6) %. Jako prakticky neidentifikovatelná travina se jeví ostřice Bigelowova (*cxbig*) s přesností 4 (3,5) %.



Obr. 12: Chybová matice nad validačními daty pro prediktory MIN a MAX, vlevo: zpracovatelská přesnost; vpravo: uživatelská přesnost - BL.

Kromě využití prediktorů ze všech měsíců zároveň bylo zkoumáno, zda by stejného výsledku nešlo dosáhnout kombinací dvou či tří měsíců. OOB skóre pro model trénovaný na prediktorech určených jako nejdůležitějších tedy MIN a MAX pro různé kombinace měsíců zobrazuje Tab. 16. Pokud byl model trénovaný pouze na dvou měsících, v případě června se OOB skóre pohybovalo na hranici 70 %. V případě kombinace, která neobsahovala červen, bylo dosaženo hodnoty kolem 75 %. Ke zlepšení došlo při kombinaci tří měsíců. Červen, srpen, a září dosáhl hodnoty 82 %, zbylé trojkombinace nad 85 %. Všechny termíny mají pozitivní vliv na výsledek trénování modelu a nelze jeden z nich vypustit bez snížení přesnosti.

	07	08	09
06	0,6831	0,7061	0,7029
07	X	0,7594	0,7612
08	X	X	0,7436
06 + 07 + 08	0,8557		
06 + 07 + 09	0,8576		
06 + 08 + 09	0,8217		
07 + 08 + 09	0,8634		

Tab. 16: OOB skóre pro prediktory MIN, MAX a model trénovaný pouze nad určitou kombinací měsíců - BL.

4.1.5. Fúze s multispektrálními daty

Klasifikace algoritmem RF probíhala multitemporálně na MS datech a rastrech strukturálních parametrů MIN a MAX určených jako důležitých. Volen byl parametr počtu stromů, který byl stanoven na 50, zvýšení jeho hodnoty nemělo vliv na výsledek. Maximální počet větvení byl stanoven v rozmezí 30 a 10000. Celková přesnost byla počítána na 3393 stratifikovaně náhodně generovaných validačních bodech.

Pro samostatná MS data byla nejvyšší celková přesnost 91,6 % a pro LiDAR odvozené strukturální parametry 67,3 %. Při jejich kombinaci bylo dosaženo vždy vyšší celkové přesnosti než při klasifikaci pouze MS dat. Nárůst celkové přesnosti se pohyboval v rozmezí 0,7 až 4,5 % v závislosti na použitých parametrech klasifikace (Tab. 17). Nejlepšího výsledku 92,3 % bylo dosaženo při nastavení RF s počtem stromů 50 a maximálním počtem větvení 5000. Ačkoliv se v tomto případě jedná pouze o 0,7% nárůst oproti klasifikaci samotných MS dat, zpracovatelská (uživatelská) přesnost vzrostla především u minoritně zastoupených tříd, které jsou ve validačních bodech zastoupeny také minoritně vzhledem ke stratifikovanému vzorkování dat. Změna v jejich individuální přesnosti se tedy projeví minimálně na celkové přesnosti klasifikace. U tříd obtížně odlišitelných z MS dat – metličky křivolaké, tomky alpské, ostrice Bigelowové (*afs*) byl pozorován nárůst zpracovatelské (uživatelské) přesnosti o 5,5 (9,3) %, nejčastěji byla špatně zařazena do třídy metlice trsnaté (*desch*). Ostrice Bigelowova dosáhla sice zpracovatelské přesnosti o 2 % vyšší, ale ta stále činila pouhých 6 %. Zároveň také došlo k poklesu uživatelské přesnosti o 25 %. LiDAR odvozené strukturální parametry nepomohly k její identifikaci. Pro smilku tuhou (*nard*)

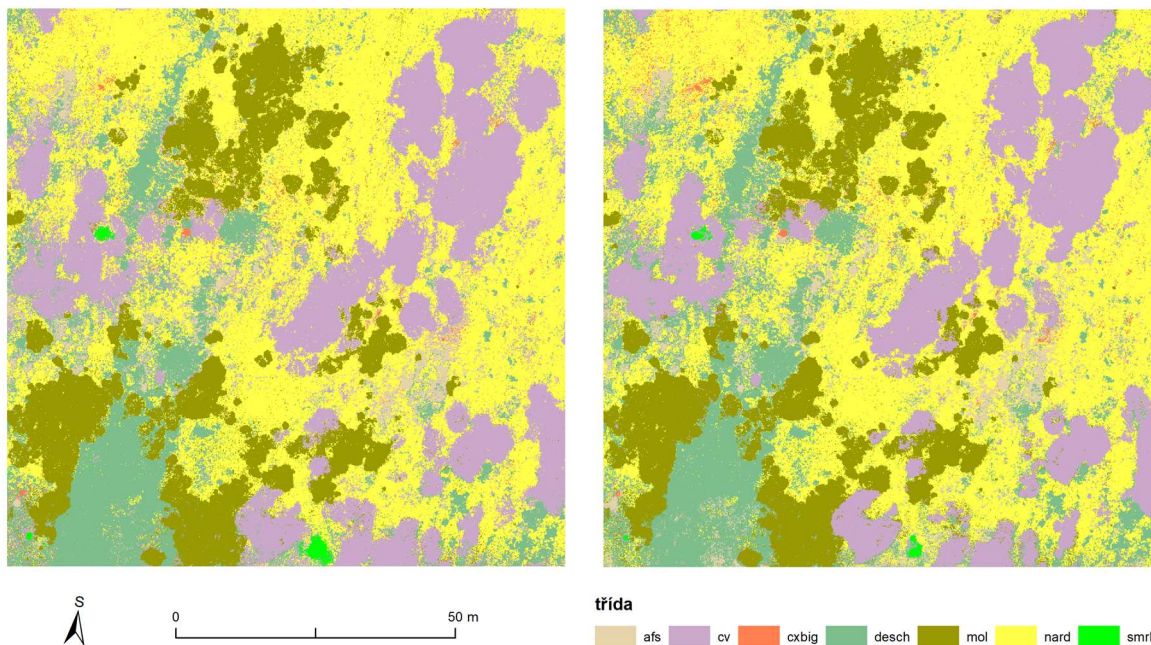
zpracovatelská přesnost vzrostla o 2,8 %, pro smrk ztepilý o 2 %. U smrku ztepilého byl očekáván vyšší nárůst přesnosti vzhledem k aplikaci LiDARu v lesních porostech a jeho schopnosti rozpoznat vyšší a nižší porosty. Při hodnocení důležitosti prediktorů jeho přesnost mono i multitemporálně činila více než 90 %. Smrk ztepilý je jednoduše identifikovatelný z ortofota, proto proběhla jeho vizuální kontrola, kde bylo zjištěno, že v případě MS dat dochází ke klasifikaci okolních travin jako smrk. Přidáním LiDAR strukturních parametrů nabude správného tvaru. Náhodné rozložení validačních bodů způsobilo, že tento konkrétní jev nebyl v hodnocení zaznamenán. Pokud k validaci byly využity všechny validační polygony, a ne pouze vybrané body, pak u smrku došlo k nárůstu zpracovatelské přesnosti o 10,3 % a uživatelské o 17,6 % na 100 %. Dané hodnoty odpovídají vizuálnímu porovnání a předpokladu, že LiDAR odvozené strukturní parametry vegetace výrazně napomohou ke klasifikaci vyšších porostů. U ostatních tříd *cv*, *desch* a *mol* se změna přesnosti pohybovala pod hranicí 1 %. Po vizuální stránce je na Obr. 13 vidět, že při kombinaci dat mají jednotlivé souvislé plochy vegetace plnější a ostřejší hranice. Chybové matice jsou znázorněny na Obr. 14.

KLASIFIKACE RANDOM FOREST BÍLÁ LOUKA, KRKONOŠE - 2020

software: Matlab
parametry RF: num of trees - 50, max num of splits - 5000
validace: 3393 bodů - stratifikované

RGB + MS - 06/07/09 - OA = 91.6 %

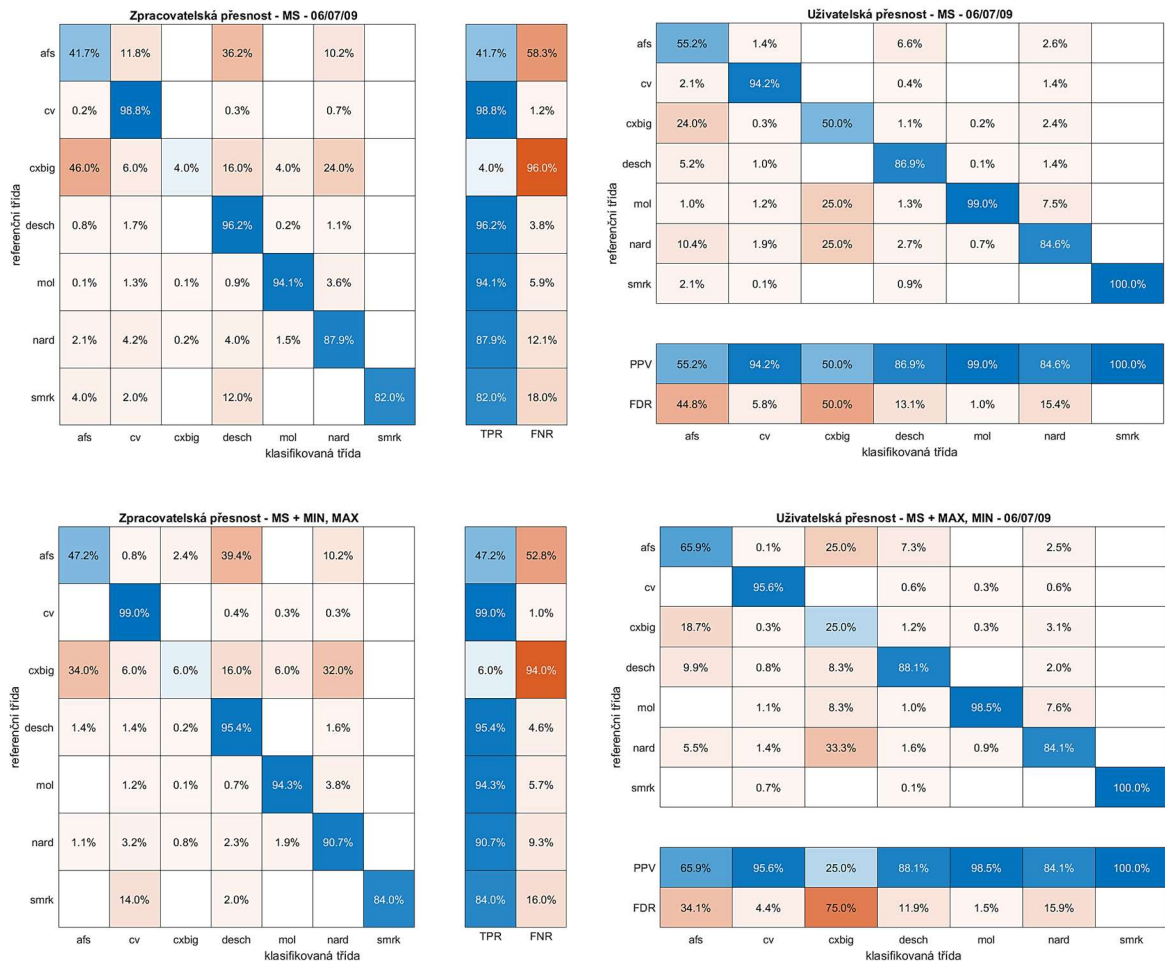
RGB + MS + MIN, MAX - 06/07/09 - OA = 92.3 %



Obr. 13: Srovnání výsledků klasifikace celého modelového území pro MS data a jejich kombinace s LiDAR strukturními parametry MIN, MAX - BL.

Počet stromů	Maximální počet větví	Validace	MS data	MAX, MIN	MS + MAX, MIN	Rozdíl
50	30	validační body	82,6	63,5	87,1	+4,5
		5-fold cross val.	82	63,1	86,1	
50	100	validační body	85,7	64,7	89,4	+3,7
		5-fold cross val.	85,8	64,9	90,3	
50	500	validační body	89,3	64,9	92	+2,7
		5-fold cross val.	91,3	67,6	94,2	
50	1000	validační body	90,8	65,9	92,2	+1,4
		5-fold cross val.	93,3	68,5	95,5	
50	5000	validační body	91,6	66,5	92,3	+0,7
		5-fold cross val.	94,6	70,5	95,9	
50	10000	validační body	91,5	67,3	92,2	+0,7
		5-fold cross val.	94,8	69,9	95,9	

Tab. 17: Celková přesnost klasifikace pro MS data a LiDAR strukturní parametry vegetace MIN, MAX - BL.



Obr. 14: Chybové matice, nahore: MS data; dole: MS data + LiDAR strukturní parametry MIN a MAX; vlevo: zpracovatelská přesnost; vpravo: uživatelská přesnost - BL.

4.1.6. Digitální model povrchu

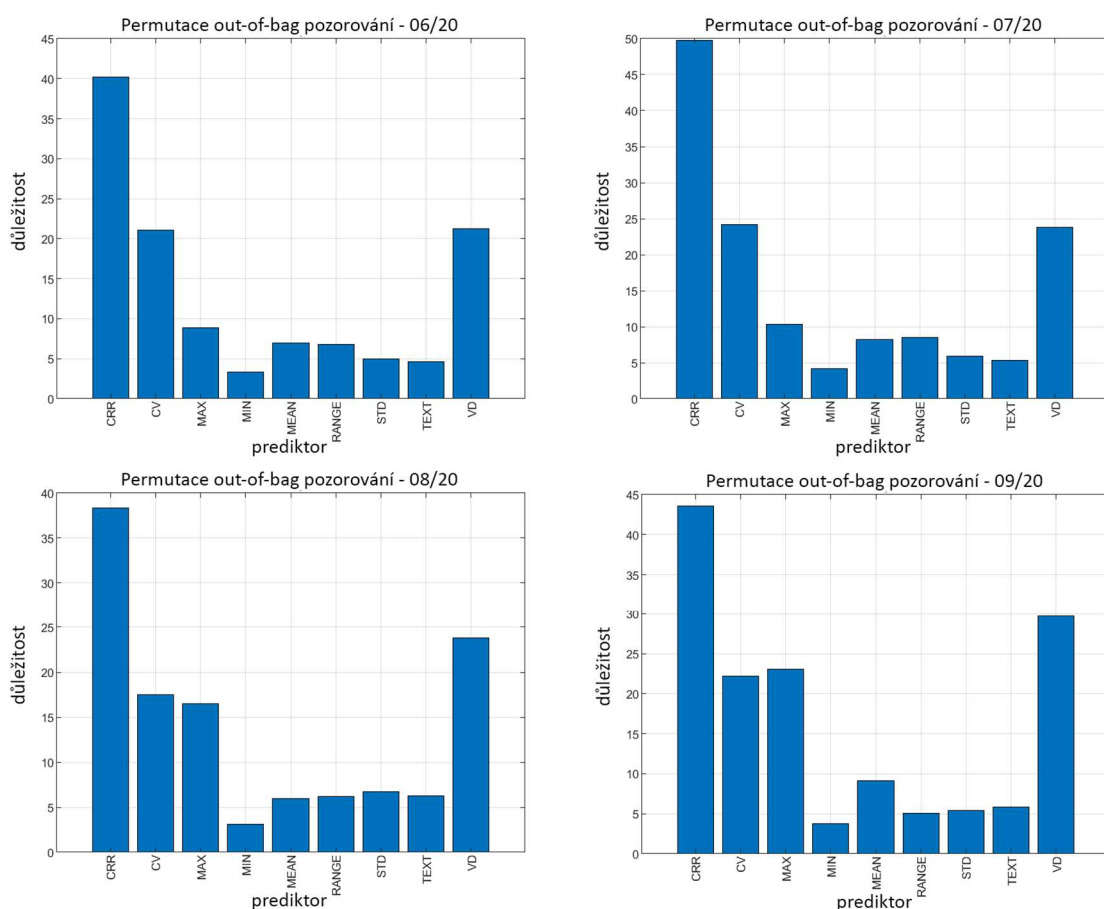
Při klasifikaci samotných rastrů struktury vegetace z DMP multitemporálně bylo dosaženo celkové přesnosti 75,2 %. Nastavení parametrů algoritmu RF zůstalo stejné jako v případě nejlepšího modelu pro MS data, tedy počet stromů 50 a maximální počet větvení 5000. Porovnáním chybových matic pouze pro LiDAR odvozené strukturní parametry a struktury vegetace DMP je patrné, že DMP lépe identifikuje všechny druhy, kromě třtiny chloupkaté (*cv*), která je sama o sobě dobře odlišitelná z LiDARových dat a smrku ztepilého, kde uživatelská (zpracovatelská) přesnost činí 56,6 (27,2) %, pro LiDAR je vyšší než 90 %. Kombinací s MS daty se celková přesnost dostala na 92,6 %, což je zanedbatelný 0,3% nárůst oproti kombinaci s LiDAR strukturními parametry. Efekt na jednotlivé druhy vegetace byl stejný u metličky křivolaké, tomky alpské, ostřice Bigelowové (*afs*), kde bylo pozorováno zvýšení uživatelské přesnosti 5,5 %, zpracovatelská přesnost ale zůstala nezměněna. U dalšího obtížně rozlišitelného druhu ostřice Bigelowové (*cxbig*) vzrostla zpracovatelská přesnost o 4 %, ale uživatelská klesla o 23,3 %. U ostatních druhů se změna pohybovala do 2 %. Ačkoliv samostatně je schopnost odlišit jednotlivé druhy u struktury vegetace DMP vyšší o 7,9 % celkové přesnosti při srovnání s LiDAR strukturními parametry, kombinací s MS daty je dosaženo prakticky stejného výsledku. Výjimku tvoří smrk ztepilý, u kterého výrazně stoupne uživatelská přesnost u LiDARu, ale DMP není schopen jej klasifikovat. Popisované chybové matice se nachází v Příloze 6.

4.2. Úpské rašeliště

4.2.1. Důležitost prediktorů

Absolutní počty úrovní jednotlivých prediktorů se lišily v závislosti na měsíci. Relativně vůči sobě ale poměr zůstal stejný. Více diskrétních hodnot měly CV, MAX, RANGE, a naopak méně CRR, STD a CV. Ostatní prediktory se nacházely mezi a počet jejich úrovní byl vyrovnaný. Prediktivní míra asociace vykazovala zvýšenou hodnotu kolem 0,7 pro MEAN a RANGE ve všech měsících a MAX a MEAN v červenci. Mezi MAX a RANGE asociace identifikována nebyla. Daný nálezn byl dále sledován. Grafické znázornění obou proměnných se nachází v Příloze 4 a 5.

Při analýze důležitosti prediktorů pomocí permutace out-of-bag pozorování byly ve všech termínech shodně určeny jako podstatné CRR, CV, MAX a VD. Prediktory MEAN, RANGE, STD a TEXT se nejevily jako závislé na vybraných druzích vegetace. Trénováním modelu na redukovaném množství prediktorů došlo ke snížení OOB skóre v červnu, srpnu a září o 0,02 a v červenci o 0,03. Přidávání dalších prediktorů v pořadí podle důležitosti nevedlo k přiblížení se OOB skóre získaného ze všech prediktorů. Výsledky OOB skóre se nachází v Tab. 18 a důležitost prediktorů na Obr. 15.



Obr. 15: Důležitost prediktorů určena metodou permutace out-of-bag pozorování - UR.

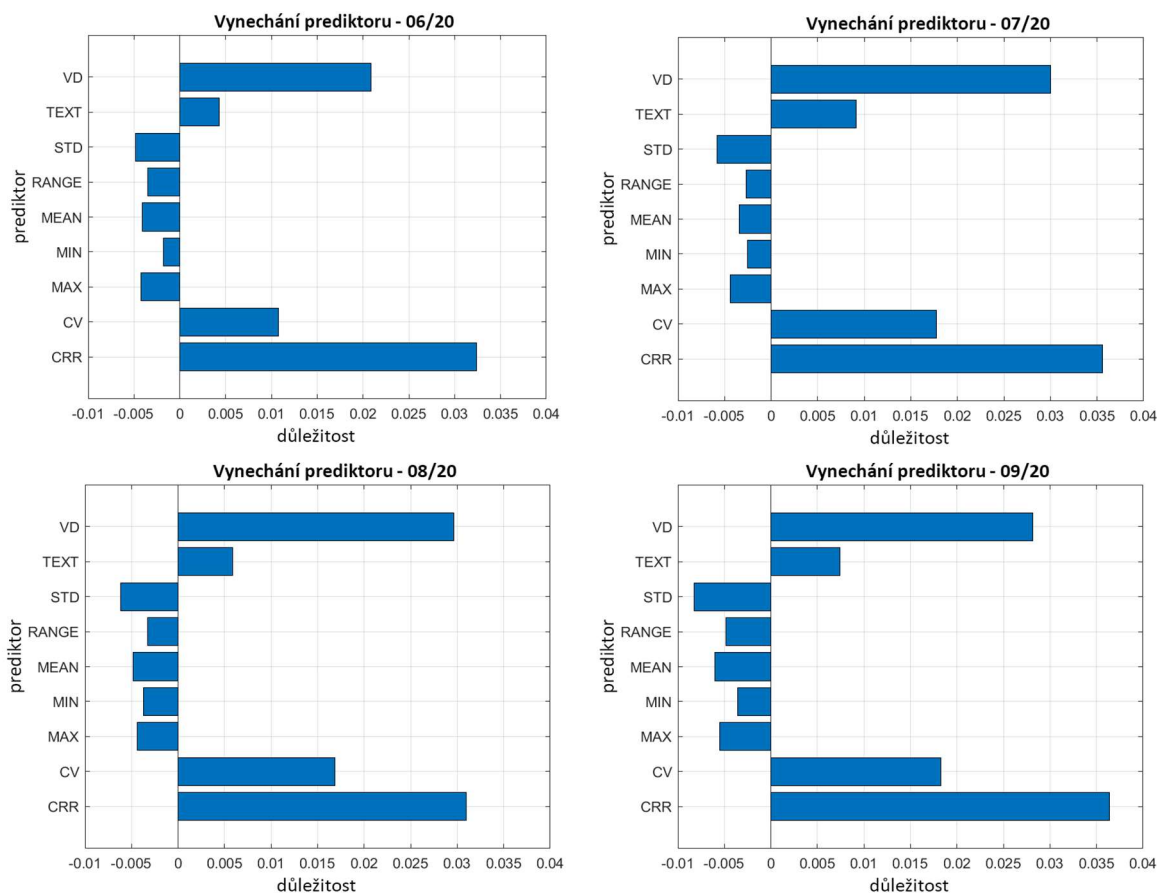
Měsíc	06	07	08	09
	OOB skóre			
všechny prediktory	0,5471	0,5885	0,5498	0,5687
redukované množství prediktorů	CRR, CV, MAX, VD	CRR, CV, MAX, VD	CRR, CV, MAX, VD	CRR, CV, MAX, VD
	0,5296	0,5581	0,5334	0,5501

Tab. 18: Hodnoty OOB skóre pro jednotlivé kombinace prediktorů - UR.

Metoda vynechání vyzdvihla prediktory CRR a VD, kde při odstranění daného prediktoru ve všech termínech došlo ke snížení OOB skóre o 2 až 3,5 %. U CV se hodnota snížila o 1 až 2 % podle měsíce. Kromě MAX se tak jedná o stejné prediktory určené pomocí permutace out-of-bag pozorování. Při vypuštění ostatních prediktorů došlo ke změně OOB skóre do 1 %. Hodnoty OOB skóre se nacházejí v Tab. 19 a rozdíl mezi OOB skóre pro model trénovaný na všech prediktorech a bez daného prediktoru je zobrazen na Obr. 16.

	VŠE	CRR	CV	MAX	MIN	MEAN	RANGE	STD	TEXT	VD
06	0,5331	0,5007	0,5223	0,5373	0,5349	0,5372	0,5366	0,5379	0,5288	0,5122
07	0,5746	0,5390	0,5568	0,5790	0,5771	0,5780	0,5772	0,5804	0,5655	0,5445
08	0,5372	0,5062	0,5203	0,5416	0,5409	0,5420	0,5404	0,5433	0,5313	0,5075
09	0,5535	0,5171	0,5352	0,5590	0,5571	0,5595	0,5583	0,5617	0,5461	0,5254

Tab. 19: Hodnoty OOB skóre při vynechání daného prediktoru - UR.



Obr. 16: Důležitost prediktorů určena na základě vynechání prediktoru - UR.

Při trénování modelu pro každý prediktor zvlášť bylo k hodnocení kvality modelu využito celkové přesnosti s využitím k-fold cross validace ($k = 5$). Lze pozorovat opačný trend, kdy prediktory MIN, RANGE, STD, TEXT, které nebyly určeny jako důležité při vynechání prediktoru, mají naopak vyšší individuální schopnost předpovídat a jejich celková přesnost se pohybuje v rozmezí 35 a 39 %. Hranici 40% přesnosti překonal jako jediný MAX ve všech měsících kromě července. Hodnoty celkové přesnosti pro individuální prediktory jsou v Tab. 20

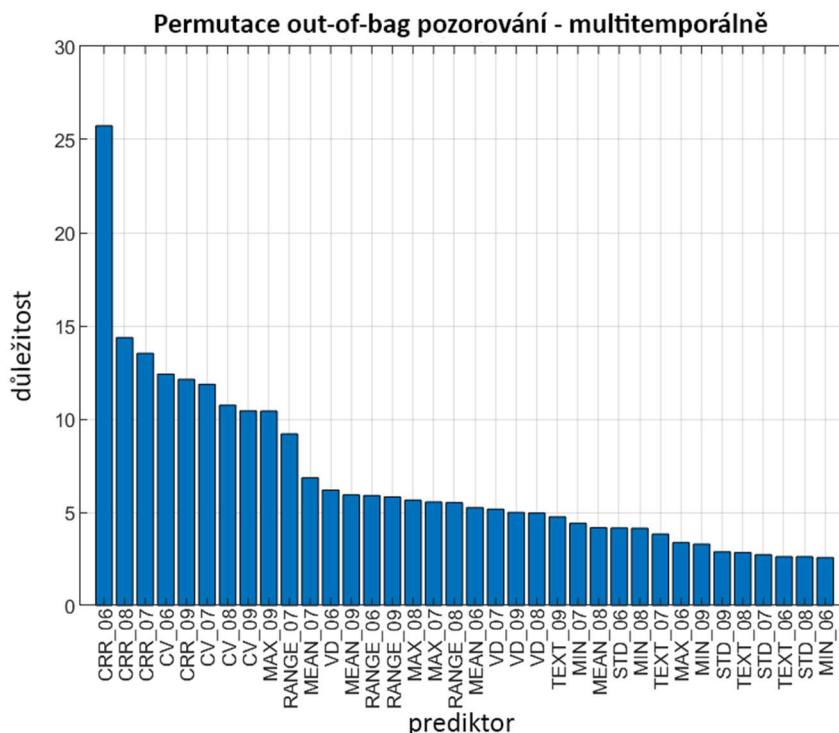
Měsíc	CRR	CV	MAX	MIN	MEAN	RANGE	STD	TEXT	VD
06	0,21	0,23	0,40	0,37	0,29	0,35	0,35	0,37	0,22
07	0,22	0,22	0,39	0,37	0,31	0,37	0,36	0,36	0,22
08	0,23	0,22	0,40	0,38	0,31	0,37	0,37	0,37	0,24
09	0,22	0,22	0,41	0,39	0,31	0,38	0,37	0,38	0,23

Tab. 20: Celková přesnost k-fold cross validace pro individuální prediktory - UR.

Co se týče jednotlivých druhů vegetace a jejich rozlišení, z chybových matic a uživatelské a zpracovatelské přesnosti k-fold cross validace ($k = 5$) nad trénovacími daty, lze vyčíst, že monotemporálně si vede dobře pouze vyšší vegetace. Smrk ztepilý a borovice kleč dosáhly ve všech termínech uživatelské i zpracovatelské přesnosti nad 90 %, případně nesprávně identifikovaný smrk byl určen právě jako borovice kleč. Třídy suchopýr pochvatý (*ervag*), smilka tuhá (*nard*), ostřice zobankatá (*rostr*), suchopýrek trsnatý a suchopýr pochvatý (*ten*) a suchopýrek trsnatý (*trich*) se většinou pohybují v rozmezí zpracovatelské přesnosti 50 až 60 %, jejich uživatelská přesnost je však nepřesvědčivá a pohybuje se v rozmezí 40 až 60 %. Do těchto tříd bývá špatně zařazena většina vegetace. Mezi naopak druhy neodlišitelné, které nedosáhly ani v jednom měsíci zpracovatelské přesnosti 30 %, lze zařadit ostřici bažinnou (*cxlim*), suchopýr uzkolistý (*erang*), rašeliník a rosnatku okrouhlostou (*ras*), vlochyni bahenní (*vaculig*), vřes obecný. Ostatní druhy vegetace se nachází v rozmezí mezi těmito dvěma skupinami.

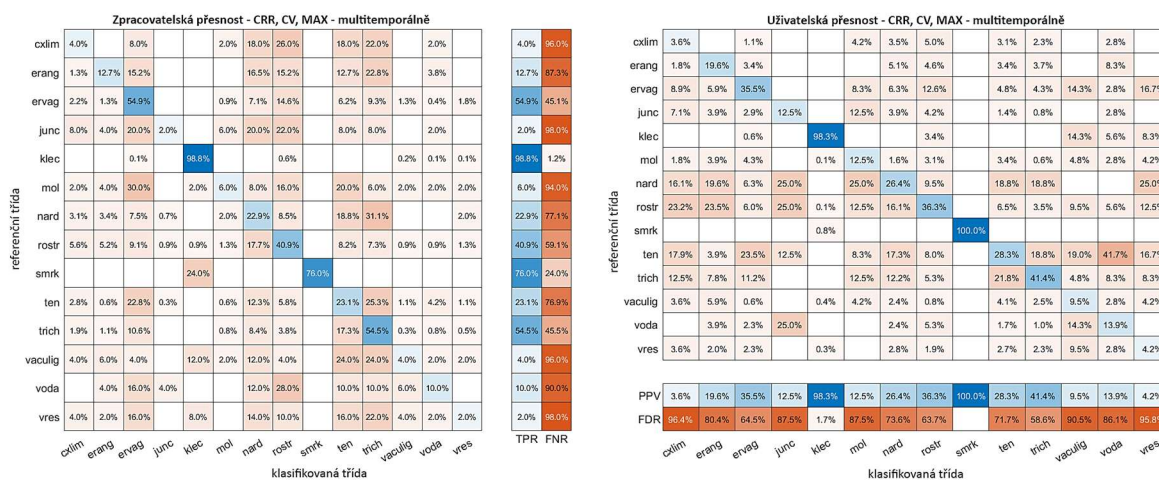
4.2.2. Multitemporální přístup

Multitemporální přístup měl pozitivní vliv na schopnost modelu klasifikovat druhy vegetace. Důležitost založená na permutaci out-of-bag pozorování (Obr. 17) opět vyzdvihla CRR a CV, které tvořily 8 nejdůležitějších prediktorů. Prvním dalším prediktorem v pořadí byl MAX z září, následovaly promíchané RANGE, MEAN, VD, MAX z různých měsíců, pro které byla hodnota důležitosti vyrovnaná. Vzhledem k výsledkům z monotemporální části a zjištěné vyšší míry asociace mezi prediktory RANGE, MEAN a MAX bylo rozhodnuto použít z této skupiny pouze MAX. Při trénování modelu na všech prediktorech bylo dosaženo OOB skóre 0,8320, redukováním na CRR, CV, MAX a VD se snížilo na 0,8283, redukováním pouze na CRR, CV, MAX na 0,8278. Pokles OOB skóre činil pro CRR, CV, MAX 0,42 % a přidáním prediktoru VD došlo k zvýšení 0,05 %. Zvolenými důležitými prediktory se staly CRR, CV a MAX.



Obr. 17: Důležitost prediktorů určena permutací out-of-bag pozorování – multitemporálně - UR.

Chybová matice pro model RF nad validačními daty s využitím prediktorů CRR, CV, MAX se nachází na Obr. 18. Borovice kleč a smrk ztepilý se znovu projeví jako závislé na vybraných prediktorech a jako jediné dvě třídy se dostaly nad hranici 90 % uživatelské či zpracovatelské přesnosti. U suchopýrku trsnatého (*trich*) a suchopýru pochvatého (*ervag*) došlo k překonání hranice zpracovatelské přesnosti 50 %, uživatelská přesnost byla ale nižší, a to 41,4 a 35,5 %. Třídy smilka tuhá (*nard*), ostřice zobankatá (*rostr*), suchopýrek trsnatý a suchopýr pochvatý (*ten*) se pohybovaly v rozmezí 20 a 40 %. Všechny ostatní druhy vegetace nedosáhly zpracovatelské ani uživatelské přesnosti 20 %.



Obr. 18: Chybová matice nad validačními daty pro prediktory CRR, CV a MAX, vlevo: zpracovatelská přesnost; vpravo: uživatelská přesnost - UR.

4.2.3. Fúze s multispektrálními daty

Úpské rašeliniště obsahuje 15 tříd určených ke klasifikaci, jedná se o 12 bylin, kosodřevinu, smrk a vodní hladinu. Rašelínik a rosnatka okrouhlolistá (*ras*) se sice nachází v legendě, ale již ne ve validačních bodech, proto byly vyřazeny. Klasifikace algoritmem RF probíhala multitemporálně na MS datech a rastrech strukturních parametrů CRR, CV a MAX určených jako důležitých. Byl zkoumán vliv nastavení parametru maximálního počtu větvení, počet rozhodovacích stromů byl ponechán konstantně 50. Celková přesnost byla počítána na 3393 stratifikovaně náhodně generovaných validačních bodech.

Pro samostatná MS data byla nejvyšší celková přesnost 82,6 % a pro LiDAR odvozené strukturní parametry 62,3 %. Při jejich kombinaci bylo dosaženo vždy vyšší celkové přesnosti než při klasifikaci pouze MS dat. Nárůst celkové přesnosti se pohyboval v rozmezí 1 až 2,6 % v závislosti na použitých parametrech klasifikace (Tab. 21). Nejlepšího výsledku 83,7 % bylo dosaženo při nastavení RF s počtem stromů 50 a maximálním počtem větvení 5000. V tomto případě se jedná o změnu 1,1 %. U smrku ztepilého, kde byl pozorován nejvyšší nárůst zpracovatelské (uživatelské) přesnosti, a to o 12 (10,6) %, došlo k eliminaci jeho záměny za suchopýrek trsnatý (*trich*) a suchopýr pochvatý (*ervag*) a byl pouze nesprávně klasifikován jako borovice kleč. Další pozitivně ovlivněné druhy byly: sítna niťovitá (*junc*) +12 (-6.7) %, ostřice zobankatá (*rostr*) +8,2 (+3,9) %, voda +6 (+0,2) %, suchopýr pochvatý (*ervag*) +3,6 (+3,37) %. U ostatních tříd, a tedy i vegetace, která byla primárně špatně odlišitelná z MS dat a její zpracovatelská přesnost nepřekročila 50 %, jmenovitě vlochyně bahenní (*vaculig*), ostřice bažinná (*cxlim*) a vřes obecný, nenapomohly LiDAR odvozené strukturní parametry k lepším výsledkům. Výstupy klasifikace pro celé modelové území se nachází na Obr. 19 a chybové matice na Obr. 20.

Počet stromů	Maximální počet větvení	Validace	MS data	CRR, CV, MAX	MS + CRR, CV, MAX	Rozdíl
50	30	validační body	70,7	57,8	73,3	+2,6
		5-fold cross val.	70,3	61,0	75,7	
50	100	validační body	75,2	57,8	77,4	+2,2
		5-fold cross val.	77,2	62,1	81,9	
50	500	validační body	79,8	59,4	82,2	+2,4
		5-fold cross val.	85,6	65,7	88,3	
50	1000	validační body	81,1	60,6	83,5	+2,4
		5-fold cross val.	88,2	67,3	91,4	
50	5000	validační body	82,6	61,9	83,7	+1,1
		5-fold cross val.	92,0	70,3	93,9	
50	10000	validační body	82,6	62,3	83,6	+1
		5-fold cross val.	92,0	70,3	94,0	



Tab. 21: Celková přesnost klasifikace pro MS data a LiDAR strukturní parametry vegetace CRR, CV, MAX - UR.

KLASIFIKACE RANDOM FOREST ÚPSKÉ RAŠELINIŠTĚ, KRKONOŠE - 2020

software: Matlab
parametry RF: num of trees - 50, max num of splits - 5000
validace: 3393 bodů - stratifikované

RGB + MS - 06/07/09 - OA = 82.6 %

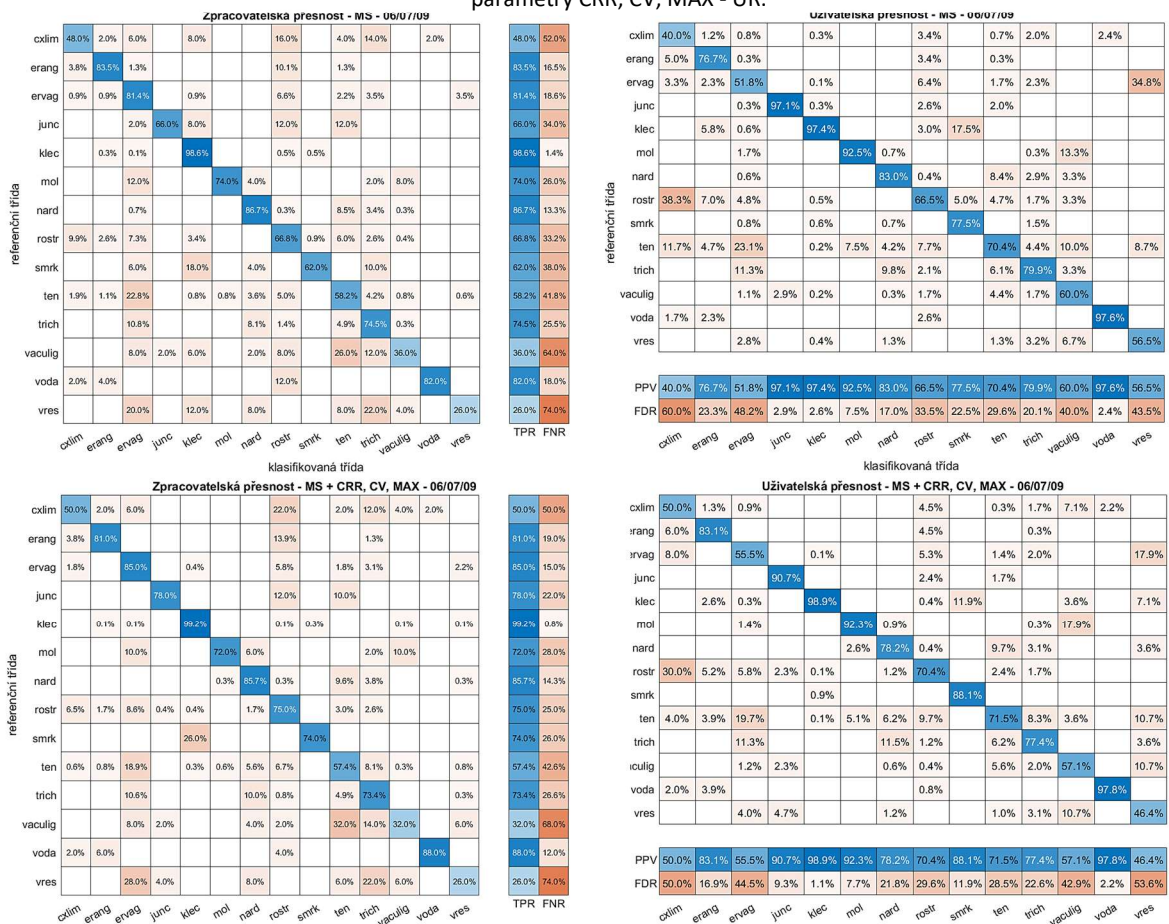
RGB + MS + CRR, CV, MAX - 06/07/09 - OA = 83.7 %



třída



Obr. 19: Srovnání výsledků klasifikace celého modelového území pro MS data a jejich kombinace s LiDAR strukturními parametry CRR, CV, MAX - UR.



Obr. 20: Chybové matice, nahoře: MS data; dole: MS data + LiDAR strukturální parametry CRR, CV, MAX; vlevo: zpracovatelská přesnost; vpravo: uživatelská přesnost - UR.

4.2.4. Digitální model povrchu

Pro klasifikaci vegetace s využitím rastrů struktury DMP bylo ponecháno totožné nastavení jako v případě nejlépe performujícího modelu MS dat, počet stromů 50 a maximální počet větvení 5000. Samostatně se rozdílové rastry DMP dostaly na celkovou přesnost 47,8 %, v případě fúze s MS daty činila přesnost 84,5 %, což je 1,9% nárůst oproti MS datům a 0,8% nárůst oproti kombinaci MS dat a LiDAR strukturních parametrů. Popisované chybové matice se nachází v Příloze 6. Nejvíce vzrostla uživatelská (zpracovatelská) přesnost u síťoviny niťovité (*junc*) o 22 (2,9) % na 88 (100) %. U špatně odlišitelné ostřice bažinné (*cxlim*) došlo ke zlepšení 12 (4,8) % a u vlochyně bahenní (*vaculig*) 6 (7,7) %. U dalších druhů, které ale primárně nejsou problematicky identifikovatelné z MS dat se změna projevila následovně: ostřice zobankatá (*rostr*) +8,6 (+4,9) %, smrk ztepilý + 6 (+14,4) %, suchopýrek trsnatý (*trich*) +5,3 (0,8), suchopýr úzkolistý (*erang*) +3,8 (+4,5) %. Ostatní vegetační třídy se pohybovaly v rámci 2 %. Výjimku tvořil vřes obecný, kde došlo k výraznému snížení -4 (-14,2) %. Vřes je však obecně nejhůře klasifikovanou třídou. Zlepšení nepřišlo ani u další obtížně rozlišitelné kategorie, a to mozaiky suchopýrku trsnatého a suchopýru pochvatého (*ten*). Nezávisle si struktura vegetace odvozená z DMP vedla podstatně hůře než LiDAR strukturní parametry, rozdíl celkové přesnosti činil 14,5 %. Při kombinaci s MS daty se ukázalo, že informace obsažená v DMP je více unikátní a má stejně pozitivní vliv na výsledek klasifikace. LiDAR si vedl lépe pouze u vyšší vegetace smrku ztepilého.

5. DISKUZE

Rešeršní část přinesla přehled používaných strukturních parametrů vegetace pro LiDARová data. Zároveň napomohla určit vhodné metody k dalšímu výběru, kdy je většinou prvotně vzato větší než potřebné množství strukturních parametrů a ty jsou následně hodnoceny podle důležitosti. Ze shrnutí, které provedl Evans et al. (2009), jich bylo vybráno 18, dále byly ještě zredukovány. Zvolené strukturní parametry byly vypočteny souhrnně nad všemi body spadajícími do stejné třídy vegetace a znázorněny v grafické podobě (Příloha 3). Snaha byla identifikovat parametry, které viditelně nenapomohou k rozlišení vegetačních tříd, jelikož jejich souhrnné hodnoty se v rámci vegetačních tříd neliší nebo jsou duplicitní a znázorňují totéž co jiný parametr. Nevyužity nebyly například jednotlivé percentily, jelikož rozdílné byly pouze absolutní hodnoty, ale poměr mezi hodnotami jednotlivých tříd vegetace zůstal stejný. Dále se jako redundantní ukázaly informace o počtu bodů *ground*, vegetace a jejich poměru, které již byly obsaženy ve VD. Medián a MEAN se v podstatě nelišily, a tak byl ponechán jen jeden z nich. Výsledná množina prediktorů určena pro další analýzu obsahovala CRR, CV, MAX, MIN, MEAN, RANGE, STD, TEXT a VD.

Jako hlavní přístup pro hodnocení důležitosti prediktorů byla vybrána permutace out-of-bag pozorování. S tím souvisí i zvolený klasifikační algoritmus RF, který hodnocení prediktorů tímto způsobem umožňuje. K určení důležitosti prediktorů pomocí RF lze také využít *Gini importance*. Permutace out-of-bag pozorování je preferovanou metodou, protože kromě vlivu každého prediktoru zvláště zkoumá i interakce mezi nimi a není náchylná ke zkreslení rozdílným měřítkem prediktorů (Strobl et al., 2017). Dále byly použity metody vynechání prediktoru a hodnocení individuální výkonnosti každého prediktoru, které nejsou závislé na zvoleném klasifikačním algoritmu. Někteří autoři (Anderson et al., 2018, Li et al., 2017) využívají postup, kdy prediktory nejdříve seřadí na základě jejich individuální schopnosti předpovídat od nejlepšího po nejhorší. Následně se vezme nejsilnější prediktor a jsou k němu přidávány další prediktory v pořadí, dokud dochází ke zvyšování celkové přesnosti klasifikace. Jako důležité prediktory jsou následně určeny ty, které vylepšily kvalitu modelu. Vzhledem k závěrům z hodnocení důležitosti prediktorů pomocí permutace out-of-bag pozorování a zjištěné individuální schopnosti jednotlivých prediktorů, kdy některé byly určeny jako důležité, ale jejich individuální výkonnost byla nízká, tento následný způsob hodnocení prediktorů nebyl využit.

Pro Bílou louku v červnu a červenci se při permutaci out-of-bag pozorování jako důležité prediktory jevíly CRR, CV, MAX, TEXT a VD. V měsíci srpnu přibyla ještě kombinace MIN a MEAN, v září pak pouze MIN. Důležitost prediktoru MIN pouze v září a srpnu je závislá na zvoleném způsobu zpracování dat. Relativní výška bodů ve všech měsících byla počítána vůči červnové referenční vrstvě *ground*. Nejnížší body v červenci měly oproti této vrstvě průměrnou odchylku 0,5 cm, u ostatních měsíců byla odchylka vyšší. Pro červen a červenec tedy hodnota

prediktoru MIN byla ve značné části pixelů 0, zatímco v srpnu a září již byla různorodá vzhledem k nárůstu vegetace. Prediktory RANGE a STD nevykazovaly spojitost s vybranými druhy vegetace ani v jednom z měsíců. V případě vynechání prediktoru došlo pro TEXT a VD k pozorovatelnému snížení OOB skóre, obsahují unikátní informaci, kterou nelze nahradit kombinací jiných prediktorů. Na druhou stranu individuální výkonnost prediktorů ukázala, že většinu informace nese MAX a MIN. Z daných výsledků a trénování modelů na redukovaném množství prediktorů bylo usouzeno, že pro vysvětlení závislosti druhů vegetace na strukturních parametrech se monotemporálně hodí CRR, CV, MIN, MAX, TEXT a VD. Multitemporální přístup znatelně vylepšil kvalitu modelu. Permutací out-of-bag pozorování a trénování modelu na redukovaném množství prediktorů bylo zjištěno, že kombinací MIN a MAX lze ze všech prediktorů nejlépe odlišit jednotlivé druhy travin. MIN by nám měl dávat informaci o výšce sušiny, respektive spodní vrstvě vegetace, kterou laserový paprsek nedokáže již penetrovat. MAX definuje výšku vegetace. Z chybových matic lze interpretovat, že by LiDARová data mohla napomoci k identifikaci především smrku ztepilého, třtiny chloupkaté (*cv*) a bezkolence modrého (*mol*).

LiDAR strukturní parametry MIN a MAX samy o sobě dosáhly maximální celkové přesnosti 67,3 % pro červen, červenec a září, MS data pak 91,6 %. Jejich fúze vedla k maximální hodnotě 92,3 %. Pozorovatelná byla vyšší přesnost klasifikace u smrku ztepilého a smilky tuhé (*nard*). Obtížně klasifikované druhy z MS dat patří do kategorie alpínských trávníků zapojených/vyfoukaných alpínských trávníků. Smíšená třída s dominantní metličkou křivolakou, tomkou alpskou a ostřicí Bigelowovou (*afs*) kromě své heterogenity je složena z malých a úzkostébelných rostlin. U ní byl pozorován nejvyšší nárůst uživatelské (zpracovatelské) přesnosti o 5,5 (9,3) %. Ostřice Bigelewova (*cxbig*) má malé zastoupení a nepříznivé charakteristiky jako úzkostébelnost a nízkou pokrývnost, zároveň ji nelze sloučit s jinou třídou. Bohužel ani příznaky charakterizující vertikální strukturu vegetace stejně jako její spektrální projev nenapomohly identifikovat daný druh. V případě odvození struktury vegetace z DMP bylo multitemporálně při fúzi s MS daty dosaženo celkové přesnosti 92,6 %. U jednotlivých druhů vegetace byl efekt totožný jako u LiDAR strukturních parametrů. Výjimku tvoří smrk ztepilý, kde DMP struktura vegetace nebyla schopná zpřesnit klasifikaci. V rámci sezóny je výška stromového porostu prakticky neměnná, ale vypočtené rozdíly výšek byly variabilní bez viditelného trendu vzhledem k způsobu pořízení a zpracování DMP.

Pro Úpské rašeliniště permutací out-of-bag pozorování byly shodně ve všech měsících určeny jako důležité CRR, CV, MAX a VD. Vynecháním prediktoru došlo ke snížení OOB skóre modelu pro CRR, CV a VD. Individuálně se jako nejvíce výkonný prediktor ukázal MAX. Druhé dva způsoby určení důležitosti prediktorů potvrdily výsledky permutace out-of-bag pozorování. Multitemporální přístup vedl znovu k zpřesnění modelu. Zde se mezi nejdůležitější prediktory dostaly CRR a CV ze všech měsíců následovány promíchanými RANGE, MEAN, VD a MAX. Trénování modelu na redukovaném počtu prediktorů a zhodnocením výsledků z monotemporální

části byla nalezena optimální kombinace CRR, CV, MAX. CV vychází ze směrodatné odchylky a průměru, neboť se jedná o jejich poměr. CRR je vypočten z minima, maxima a průměru relativních výšek. Při zaměření se na jednotlivé druhy zvládly vybrané prediktory identifikovat borovici kleč a smrk ztepilý, dále by také mohly napomoci především u suchopýrku trsnatého (*trich*), suchopýru pochvatého (*ervag*) a ostřice zobánkaté (*rostr*).

LiDAR strukturní parametry CRR, CV, MAX samy o sobě dosáhly maximální celkové přesnosti 62,3 % pro červen, červenec a září dohromady, MS data pak 82,6 %. Jejich fúze vedla k maximální hodnotě 83,7 %. Předpoklad vyšší přesnosti klasifikace se potvrdil u smrku ztepilého, ostřice zobánkaté (*rostr*) a suchopýru pochvatého (*ervag*). Borovice kleč je obecně jednoduše klasifikovatelnou třídou z MS (Marcinkowska-Ochtyra et al., 2020) i HS dat (Kupková et al., 2017). Poměrně překvapivý byl nárůst přesnosti u síťoviny níťovité (*junc*) a vody, které při klasifikaci pouze LiDAR strukturních parametrů patřily mezi nejhorší třídy. Bohužel ani u jedné problematicky odlišitelné třídy z MS dat, mezi které patří úzkostébelná ostřice bažinná (*cxlim*) vyskytující se v oblasti mělkých vodních ploch, vlochyně bahenní (*vaculig*) po okrajích kosodřevinových porostů, smíšená mozaika úzkostébelného suchopýrku trsnatého a suchopýru pochvatého (*ten*) a trsovité vřes obecný s celkově malým zastoupením, nedošlo k zpřesnění klasifikace. Vřes obecný je druh obtížně odlišitelný i z HS snímků (Marcinkowska-Ochtyra et al., 2017; Marcinkowska-Ochtyra et al., 2018b.). V případě odvození rastrů struktury vegetace z DMP bylo při fúzi s MS daty dosaženo celkové přesnosti 84,5 %. Na rozdíl od LiDAR strukturních parametrů zde bylo pozorováno zlepšení i u ostřice bažinné (*cxlim*) a vlochyně bahenní (*vaculig*). U všech tříd kromě smrku ztepilého byl zároveň nárůst přesnosti vyšší.

Bíla louka a Úpské rašeliniště jsou dvě území lišící se nejen svojí polohou ale i druhovým složením. Nižší přesnost klasifikace v oblasti Úpského rašeliniště je způsobena heterogenitou a vysokou roční a sezónní variabilitou. Nachází se zde smíšené druhy vegetace a druhy s malým zastoupením. Ačkoliv pro každé území vyšla ve výsledku jako důležitá rozdílná kombinace strukturních parametrů vegetace, shoda nastala u parametru MAX. Maximální výšku určil jako vhodný parametr pro nízkou vegetaci i Kulawardhana et al. (2014) pro odhad výšky u travin mokřadních společenstev, Anderson et al. (2018) pro mapování druhového zastoupení a Luo et al. (2017) pro výpočet AGB u rákosu. CRR a CV nebyly sice využity v oblasti Bílé Louky, ale v multitemporálním hodnocení důležitosti prediktorů se nacházely hned v závěsu za MAX a MIN. Absence parametru MIN u Úpského rašeliniště může být způsobena rozdílným použitým filtračním a klasifikačním postupem pro obě území. Pro širší oblast krkonošské tundry by se tedy za vhodné strukturní parametry vegetace dal označit průnik parametrů z obou území. V obou případech vedla fúze LiDARu s MS daty ke zvýšení přesnosti klasifikace. Bork a Su (2007) klasifikoval vegetaci pastvin z MS dat a přidáním příznaků odvozených z LiDARu došlo k zvýšení přesnosti o 16 až 20 %. Dechesne et al. (2012) pro homogenní lesní porosty dosáhl zpřesnění klasifikace o 15 %. Nárůst

přesnosti klasifikace byl u těchto i většiny dalších autorů v řádech desítek procent, zatímco u Bílé louky a Úpského rašeliniště se jednalo pouze o jednotky procent. První důvod je relativně vysoká přesnost klasifikace už samotných MS dat, především u Bílé louky, nenabízí se zde tedy tak velký prostor pro zlepšení. Dále se jednalo o jiný druh vegetace. Odvozené strukturní parametry se neukázaly jako vhodné pro odlišení nízké vegetace. Pokud by jediným cílem pořizování LiDARových dat bylo zpřesnění klasifikace travin z optických dat, pak se to při vysoké pracovní a časové náročnosti jeví jako nadbytečné, vzhledem k minimálnímu zvýšení přesnosti a zjištění, že stejného výsledku lze dosáhnout i v případě struktury vegetace DMP získané MS dat. Strukturní parametry odvozené z LiDARového snímání zvládly odlišit především vyšší porosty, a to smrk ztepilý a borovice kleč. Potvrzena tak byla vhodnost pro lesnictví (Li et al., 2013; Falkowski et al., 2009; Marselis et al., 2018).

Jako jediná z mála se podobným výzkumem a následnou fúzí s HS daty se zabývala Marcinkowska-Ochtyra et al. (2018a.), která klasifikovala z LiDARových dat nejdříve zvlášť bezkoleneček modrý (*mol*) a poté třtinu křovištní. U bezkolence modrého (*mol*) dosáhla vyšší celkové přesnosti než u třtiny křovištní. V případě Bílé louky byla naopak třtina chloupkatá (*cv*) travina s nejvyšší zpracovatelskou přesností 92,4 % u LiDARových dat. Bezkoleneček modrý (*mol*) dosáhl 70,5 % na Bílé louce, ale pouze 6 % v Úpském rašeliništi, kde má nižší zastoupení a tvoří menší trsy. Porovnáním všech hodnot je patrné, že v případě kdy je druh dobře identifikovatelný na jednom území, automaticky neznamená, že bude dobře odlišitelný i jinde. Záleží na jeho zastoupení, rozložení a jaké jiné druhy s podobnou vertikální strukturou se v dané oblasti vyskytují. Výsledky musí být interpretovány s opatrností a vhodnost metod je vázána na konkrétní území a druhy.

Je třeba zmínit, že do výsledků se promítají omezení spojená s LiDAREm jako technologií a použitý zpracovatelský postup. Vzdálenosti mezi skenovanými pásy a existující systematický posun mezi měsíci, který nelze plně eliminovat, nemusí hrát roli pro lesní porosty, ale v případě travních společenstev, kde se pracuje v řádech centimetrů, to může být problematické. Vlivem hustého porostu a sušiny není detekován přímo reliéf, ale jakási spodní vrstva vegetace, který by v ideálním případě měla skutečný reliéf kopírovat. Při výpočtu relativní výšky vegetace je tak výška podhodnocena, což potvrdilo provedené měření v terénu. Daná zjištění odpovídají Vosselman a Maas (2010), kteří popisují, že k podhodnocování výšky vegetace dochází vlivem neschopnosti laserového paprsku penetrovat skrze hustý porost, podzorkováním povrchu a ohybem ve větru.

Zajímavé by do budoucna mohlo být využití poměrně nových MS LiDARových systémů, které pořizují data ve více vlnových délkách a umožňují zaznamenávat diverzitu spektrální odrazivosti objektů (Morsy et al., 2017). Současné MS senzory umožňují snímat hlavně horní vrstvu vegetace. MS LiDAR by měl být schopný měřit jak strukturní parametry vegetace, tak vertikální fyziologické změny porostu, což by dále umožnilo lépe separovat reliéf a druhy vegetace (Wallace et al., 2012).

6. ZÁVĚR

Řešená práce vycházela z hypotézy, že lze identifikovat příznaky charakterizující vertikální strukturu vegetace z UAV LiDARových dat, které napomohou ke zvýšení přesnosti klasifikace vybraných druhů arкто-alpínské tundry Krkonoš v porovnání s klasifikací pouze MS dat.

Výzkum probíhal pro dvě rozdílná modelová území v krkonošské tundře – Bílou louku a Úpské rašeliniště. U poskytnutých předzpracovaných LiDARových dat byla provedena filtrace a klasifikace bodového mračna, aby následně mohly být vypočteny relativní výšky a odvozeny strukturní parametry vegetace. Prvním cílem bylo vytipovat vhodné parametry, ty byly vybrány podle rešerše literatury zaměřené na nízké ale i lesní porosty. K určení, které strukturní parametry mají schopnost odlišit vybrané druhy vegetace, a tedy splnění dalšího cíle práce, bylo využito klasifikačního algoritmu RF a hodnocení důležitosti prediktorů pomocí permutace out-of-bag pozorování, vynechání prediktoru a individuální výkonnosti prediktorů. Na základě mono i multitemporálního přístupu byly vybrány prediktory MIN, MAX pro Bílou louku a CRR, CV, MAX pro Úpské rašeliniště. Dále si práce kladla za cíl provést fúzi s MS daty. Pro samostatné LiDAR odvozené strukturní parametry bylo multitemporálně dosaženo celkové klasifikační přesnosti 67,3 % pro Bílou louku a 62,3 % pro Úpské rašeliniště, fúze přinesla pouze zpřesnění klasifikace MS dat do 2 %. Posledním dílčím cílem práce bylo zhodnotit, do jaké míry lze zpřesnění klasifikace dosáhnout s využitím DMP získaného obrazovou korelací MS dat. Byly odvozeny strukturní parametry jako rozdíly výšek ze srpna, září a listopadu oproti červnovému termínu. V případě fúze s MS daty bylo dosaženo obdobného výsledku jako v případě LiDAR odvozených strukturních parametrů s výjimkou vyšší vegetace, kterou DMP struktura vegetace nebyla schopna rozlišit.

Všechny určené cíle práce byly splněny. Hypotéza stanovená v úvodu byla potvrzena pouze částečně. Vertikální struktura vegetace ani při extrémní hustotě bodového mračna nepřinesla komplementární informaci k spektrálnímu projevu travních společenstev. Prokázána byla pouze aplikovatelnost LiDARu u vyšších porostů, kde došlo k výraznějšímu nárůstu přesnosti u smrku ztepilého. Borovice kleč byla také jednoduše identifikovatelná z LiDARových dat. U některých dalších druhů došlo k mírnému zlepšení výsledků klasifikace.

LiDARová data se neukázala jako vhodná ke zvýšení přesnosti klasifikace travin. Z existujících LiDARových dat z krkonošské tundry by však mohly být získány informace například o výšce vegetace a její změně v čase nebo by mohly být na jejich základě vymezeny stromové porosty. Případně by mohla posloužit k nedestruktivnímu výpočtu AGB u nízké vegetace, kde již možná aplikovatelnost LiDARu byla prokázána v dřívějších studiích. Vzhledem k tomu, že obě modelová území dosáhla relativně vysoké přesnosti klasifikace z MS dat, dalším krokem bude vyzkoušet přenositelnost již existujících metod na rozsáhlejší oblast tundry a prozkoumat možnost jejich využití pro dlouhodobé monitorování.

Použité zdroje

- ANDERSON, E. K.; GLENN, F. N.; SPAETE, P. L.; SHINNEMAN, J. D.; PILLIOD, S. D.; ARKLE, S. R.; MCILROY, K. S.; DERRYBERRY, R. D. (2018): Estimating vegetation biomass and cover across large plots in shrub and grass dominated drylands using terrestrial lidar and machine learning. *Ecological Indicators*, 84, 793-802.
- BHATIA, M. (2019): What is Out of Bag (OOB) score in Random Forest? [online]. towardsdatascience.com/what-is-out-of-bag-oob-score-in-random-forest-a7fa23d710/ [cit. 2021-10-30].
- BORK, E. W.; SU, J. G. (2007): Integrating LIDAR data and multispectral imagery for enhanced classification of rangeland vegetation: A meta analysis. *Remote Sensing of Environment*, 111(1), 11-24.
- BREIMAN, L. (2001): Random Forests. *Machine Learning*, 45, 5-32.
- BREIMAN, L. (2002): Manual on setting up, using, and understanding Random Forests v3.1. [dokumentace]. stat.berkeley.edu/~breiman/Using_random_forests_V3.1.pdf/.
- BUCKSCH, A.; LINDENBERGH, R.; ABD RAHMAN, M.; MENENTI, M. (2014): Breast Height Diameter Estimation From High-Density Airborne LiDAR Data. *IEEE Geoscience and Remote Sensing Letters*, 11, 1056-1060.
- CONGALTON, R.G.; GREEN, K. (2009): Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Lewis Publishers, Boca Raton.
- ČERVENÁ, L.; KUPKOVÁ, L.; POTŮČKOVÁ, M.; LYSÁK, J. (2020): Seasonal Spectral Separability of Selected Grasses: Case Study from The Krkonoše Mts. Tundra Ecosystem. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2020, 371–376.
- DALPONTE, M.; BRUZZONE, L.; GIANELLE, D. (2012): Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote Sensing of Environment*, 123, 258-270.
- DECHESNE, C.; MALLET, C.; BRIS, A. L.; GOUET-BRUNET, V. (2017): Semantic segmentation of forest stands of pure species combining airborne lidar data and very high resolution multispectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 126, 129-145.

- DOLANSKÝ, T. (2004): Lidary a letecké laserové skenování. Univerzita J. E. Purkyně, Ústí nad Labem. ISBN 8070445750.
- DONG, P.; CHEN, Q. (2018): LiDAR Remote Sensing and Applications. CRC Press, Boca Roton. ISBN 9781482243017.
- EVANS, S. J.; HUDAK, A. T.; FAUX, R.; ALISTAIR, S. (2009): Discrete Return Lidar in Natural Resources: Recommendations for Project Planning, Data Processing, and Deliverables. *Remote Sensing*, 1, 776-794.
- FALKOWSKI, J. M.; EVANS, S. J.; MARTINUZZI, S.; GESSLER, E. P.; HUDAK, T. A. (2009): Characterizing forest succession with lidar data: An evaluation for the Inland Northwest, USA. *Remote Sensing of Environment*, 113, 946-956.
- FOODY, G.M. (2009): Sample size determination for image classification accuracy assessment and comparison. *International Journal of Remote Sensing*, 30(20), 5273-5291.
- GRILLI, E., MENNA, F.; REMONDINO, F. (2017): A review of point clouds segmentation and classification algorithms. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W3, 339-344.
- GUO, X.; COOPS, N. C.; TOMPALSKI, P.; NIELSEN, E. S.; BATER, W. C.; STADT, J. J. (2017): Regional mapping of vegetation structure for biodiversity monitoring using airborne lidar data. *Ecological Informatics*, 38, 50-61.
- HARTFIELD, K. A.; LANDAU, K. I.; LEEUWEN, W. (2011): Fusion of High Resolution Aerial Multispectral and LiDAR Data: Land Cover in the Context of Urban Mosquito Habitat. *Remote Sensing*, 3, 2364-2383.
- JAROCIŃSKA, A.; KACPRZYK, M.; MARCINKOWSKA-OCHTYRA, A.; OCHTYRA, A.; ZAGAJEWSKI, B.; MEULEMAN, K. (2016): The application of APEX images in the assessment of the state of non-forest vegetation in the Karkonosze Mountains. *Miscellanea Geographica*, 20(1), 21-27.
- JĘDRYCH, 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), 107-119.
- JENSEN, J. R. (2015): Introductory Digital Image Processing: A Remote Sensing Perspective. Pearson, USA. ISBN 9780134395166.
- KAZEMITABAR, J.; AMINI, A; BLONIAZ, A; TALWALKAR, A. (2017): Variable Importance using Decision Trees. *Advances in Neural Information Processing Systems*, 30.

- KOCIÁNOVÁ, M.; ŠTURSA, J. (2015): Krkonošská tundra. Správa KRNAP, Vrchlabí. ISBN 9788087706954.
- KUKUNDA, C. B.; DUQUE-LAZO, J.; GONZÁLEZ-FERREIRO, E.; THADEN, H.; KLEINN, C. (2018): Ensemble classification of individual Pinus crowns from multispectral satellite imagery and airborne LiDAR. *International Journal of Applied Earth Observation and Geoinformation*, 65, 12-23.
- KULAWARDHANA, W. R.; POPESCU, C. S.; FEAGIN, A. R. (2014): Fusion of lidar and multispectral data to quantify salt marsh carbon stocks. *Remote Sensing of Environment*, 154, 345-357.
- KUPKOVÁ, L.; ČERVENÁ, L.; SUCHÁ, R.; JAKEŠOVÁ, L.; ZAGAJEWSKI, B.; BŘEZINA, S.; ALBRECHTOVÁ, J. (2017): Classification of Tundra Vegetation in the Krkonoše Mts. National Park Using APEX, AISA Dual and Sentinel-2A Data. *European Journal of Remote Sensing*, 50(1), 29-46.
- LEE, W-J.; LEE, CH-W. (2018): Forest Canopy Height Estimation Using Multiplatform Remote Sensing Dataset. *Sensor Technologies and Methods for Geoinformatics and Remote Sensing*, 2018.
- LI, A.; DHAKAL, S.; GLENN, F. N.; SPAETE, P. L.; SHINNEMAN, J. D.; PILLIOD S. D.; ARKLE, S. R.; MCILROY K. S. (2017): Lidar Aboveground Vegetation Biomass Estimates in Shrublands: Prediction, Uncertainties and Application to Coarser Scales. *Remote Sensing*, 9(9), 903.
- LI, J.; HU, B.; NOLAND, L. T. (2013): Classification of tree species based on structural features derived from high density LiDAR data. *Agricultural and Forest Meteorology*, 171-172, 104-114.
- LI, Q.; WONG, F.; FUNG, T. (2021): Mapping multi-layered mangroves from multispectral, hyperspectral, and LiDAR data. *Remote Sensing of Environment*, 258(3), 112403.
- LILLESAND, T.; KIEFER, R.; CHIPMAN, J. (2015) Remote Sensing and Image Interpretation. Wiley, USA. ISBN 9781118343289.
- LOH, W.Y. (2002): Regression Trees with Unbiased Variable Selection and Interaction Detection. *Statistica Sinica*, 12, 361–386.
- LUO, S.; WANG, C.; XI, X.; PAN, F.; QIAN, M.; PENG, D.; NIE, S.; QIN, H.; LIN, Y. (2017): Retrieving aboveground biomass of wetland *Phragmites australis* (common reed) using a combination of airborne discrete-return LiDAR and hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 58, 107-117.

- MANZANERA, J. A.; GARCÍA-ABRIL, A.; PASCUAL, C.; TEJERA, R.; MARTÍN-FERNÁNDEZ, S.; TOKOLA, T.; VALBUENA, R. (2017): Fusion of airborne LiDAR and multispectral sensors reveals synergic capabilities in forest structure characterization. *GIScience and Remote Sensing*, 53(6), 723-738.
- MARCINKOWSKA, A.; ZAGAJEWSKI, B.; OCHTYRA, A.; JAROCIŃSKA, A.; RACZKO, E.; KUPKOVÁ, L.; STYCH, P.; MEULEMAN, K. (2014): Mapping vegetation communities of the Karkonosze National Park using APEX hyperspectral data and Support Vector Machines. *Miscellanea Geographica*, 18(2), 23-29.
- MARCINKOWSKA-OCHTYRA, A.; JAROCIŃSKA, A.; BZDEGA, K.; TOKARSKA-GUZIŁ, B. (2018a.): Classification of Expansive Grassland Species in Different Growth Stages Based on Hyperspectral and LiDAR Data. *Remote Sensing*, 10(12), 2019.
- MARCINKOWSKA-OCHTYRA, A.; ZAGAJEWSKI, B.; OCHTYRA, A.; JAROCINSKA, A.; WOJTUŃ, B.; ROGAß, CH.; MIELKE, CH.; LAVENDER, S. (2017): Subalpine and alpine vegetation classification based on hyperspectral APEX and simulated EnMAP images. *International Journal of Remote Sensing*, 38, 1839-1864.
- MARCINKOWSKA-OCHTYRA, A.; ZAGAJEWSKI, B.; RACZKO, E.; OCHTYRA, A.; JAROCINSKA, A. (2018b.): Classification of High-Mountain Vegetation Communities within a Diverse Giant Mountains Ecosystem Using Airborne APEX Hyperspectral Imagery. *Remote Sensing*, 10(2).
- MARCINKOWSKA-OCHTYRA, A.; WAKULIŃSKA, M. (2020): Multi-Temporal Sentinel-2 Data in Classification of Mountain Vegetation. *Remote Sensing*, 12(17).
- MARSELIS, M. S.; TANG, H.; ARMSTON, D. J.; CALDERS, K.; LABRIÈRE, N.; DUBAYAH, R. (2018): Distinguishing vegetation types with airborne waveform lidar data in a tropical forest-savanna mosaic: A case study in Lopé National Park, Gabon. *Remote Sensing of Environment*, 216, 626-634.
- MATHWORKS (2021): Statistics and Machine Learning Toolbox User's Guide [dokumentace]. [mathworks.com/help/pdf_doc/stats/stats.pdf/](https://www.mathworks.com/help/pdf_doc/stats/stats.pdf/).
- MORSY, S.; SHAKER, A.; EL-RABBANY, A. (2017): Multispectral LiDAR data for land cover classification of urban areas. *Sensors*, 17(5), 958.
- MÜLLEROVÁ, J. (2005): Use of digital aerial photography for sub-alpine vegetation mapping: A case study from the Krkonoše Mts., Czech Republic. *Plant Ecology*, 175(2), 259–272.

- NÆSSET, E. (1997): Estimating timber volume of forest stands using airborne laser scanner data. *Remote Sensing of Environment*, 61(2).
- PONT, D.; KIMBERLEY, M.; BROWNLIE, R.; MORGENROTH, J.; WATT, M. (2015): Tree counts from airborne LiDAR. *New Zealand Journal of Forestry*, 60, 38-43.
- POPESCU, S. C.; WYNNE, R. H.; SCRIVANI, J. A. (2004): Fusion of Small-Footprint Lidar and Multispectral Data to Estimate Plot-Level Volume and Biomass in Deciduous and Pine Forests in Virginia, USA. *Forest Science*, 50(4), 551–565.
- RIEGL LASER MEASUREMENT SYSTEMS (2021): RIEGL miniVUX-1UAV [online]. riegl.com/products/unmanned-scanning/riegl-minivux-1uav/ [cit. 2021-10-12].
- RICHARDS, J. A. (2013): Remote Sensing Digital Image Analysis. Springer, Heidelberg. ISBN 9783642300622.
- SANDRI, M.; ZUCCOLOTTO, P (2008): A bias correction algorithm for the Gini variable importance measure in classification trees. *Journal of Computational and Graphical Statistics*. 17(3), 611-628.
- SHI, Y.; WANG, T.; SKIDMORE, K. A.; HEURICH, M. (2018): Important LiDAR metrics for discriminating forest tree species in Central Europe. *ISPRS Journal of Photogrammetry and Remote Sensing*, 137, 163-174.
- SOUKUPOVÁ, L.; KOCIÁNOVÁ, M.; JENÍK, J.; SEKYRA, J. (1995): Arctic-alpine tundra in the Krkonoše, the Sudetes. *Opera Corcontica*, 32, 5-88.
- SPRÁVA KRNAP (2010): Plán péče o Krkonošský národní park a jeho ochranné pásmo [online]. krnap.cz/data/File/letaky_brozury/planpeceweb.pdf/ [cit. 2021-11-03].
- SPRÁVA KRNAP (2019): Popis zonace Krkonošského národního parku [online]. krnap.cz/data/Files/pages/popis-zonace-krnap-rada-np-2019-1-16_154840936704.756.docx [cit. 2021-10-06].
- SPRÁVA KRNAP (2021a.): Přírodní poměry [online]. krnap.cz/prirodni-pomery/ [cit. 2021-10-06].
- SPRÁVA KRNAP (2021b.): Vegetace krkonošské tundry – minulost, současnost a budoucnost [online]. krnap.cz/vegetace-krkonosske-tundry/ [cit. 2021-10-06].
- STREUTKER, R. D.; GLENN, F. N. (2006): LiDAR measurement of sagebrush steppe vegetation heights. *Remote Sensing of Environment*, 102, 135-145.

- STROBL, C. (2008): Statistical Issues in Machine Learning – Towards Reliable Split Selection and Variable Importance Measures. *Ludwig-Maximilians-Universität München*, Dissertation.
- STROBL, C.; BOULESTEIX, A.; ZEILEIS, A.; HOTHORN, T. (2007): Bias in random forest variable importance measures: Illustrations, sources and a solution. *BMC Bioinformatics*, 8(25).
- SU, W.; LIU, R.; LIU, T.; HUANG, J.; ZHANG, X.; LIU, J. (2012): The Estimation of Tree Height Based on LiDAR Data and QuickBird Imagery. *Computer and Computing Technologies in Agriculture*, 6, 472-482.
- 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.
- SWATANTRAN, A; DUBAYAH, R; GOETZ, S; HOFTON, M; BETTS, M. G.; SUN, M.; SIMARD, M.; HOLMES, R. (2012): Mapping Migratory Bird Prevalence Using Remote Sensing Data Fusion. *PLoS ONE*, 7(1).
- ŠTURSA, J. (2013): Arktoalpínská tundra Krkonoš. *Živa*, 4, 171–174.
- THERS, H.; BRUNBJERG, K. A.; LÆSSØE, T.; EJRNÆS, R.; BØCHER, K. P.; SVENNING, J. (2017): Lidar-derived variables as a proxy for fungal species richness and composition in temperate Northern Europe. *Remote Sensing of Environment*, 200, 102-113.
- VOSSSELMAN, G. (2000): Slope based filtering of laser altimetry data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIII, 935-942.
- VOSSSELMAN, G; MAAS, H-G (2010): Airborne and Terrestrial Laser Scanning. Whittles Publishing, Caithes. ISBN 9781904445876.
- WALLACE, A.; NICHOL, C.; WOODHOUSE, I. (2012): Recovery of Forest Canopy Parameters by Inversion of Multispectral LiDAR Data. *Remote Sensing*, 4, 509-531.
- XIE, Y.; SHA, Z.; YU, M. (2008): Remote sensing imagery in vegetation mapping: A review. *Journal of Plant Ecology*, 1(1), 9–23.

Seznam příloh

Příloha 1: Rozdíly ve výšce VLB geodeticky zaměřených a určených z LiDARového snímání pro Bílou louku a Úpské rašeliniště.

Příloha 2: Seznam širšího výběru strukturních parametrů vegetace.

Příloha 3: Statistiky (strukturní parametry) vypočteny nad relativními výškami všech bodů daného druhu.

Příloha 4: Počet úrovní prediktorů.

Příloha 5: Prediktivní míra asociace.

Příloha 6: Chybové matice pro fúzi MS dat a DMP struktury vegetace.

Digitální přílohy: Výsledky klasifikace pro fúzi MS a LiDARových dat ve vyšším rozlišení a formátu *.pdf a *.tif.

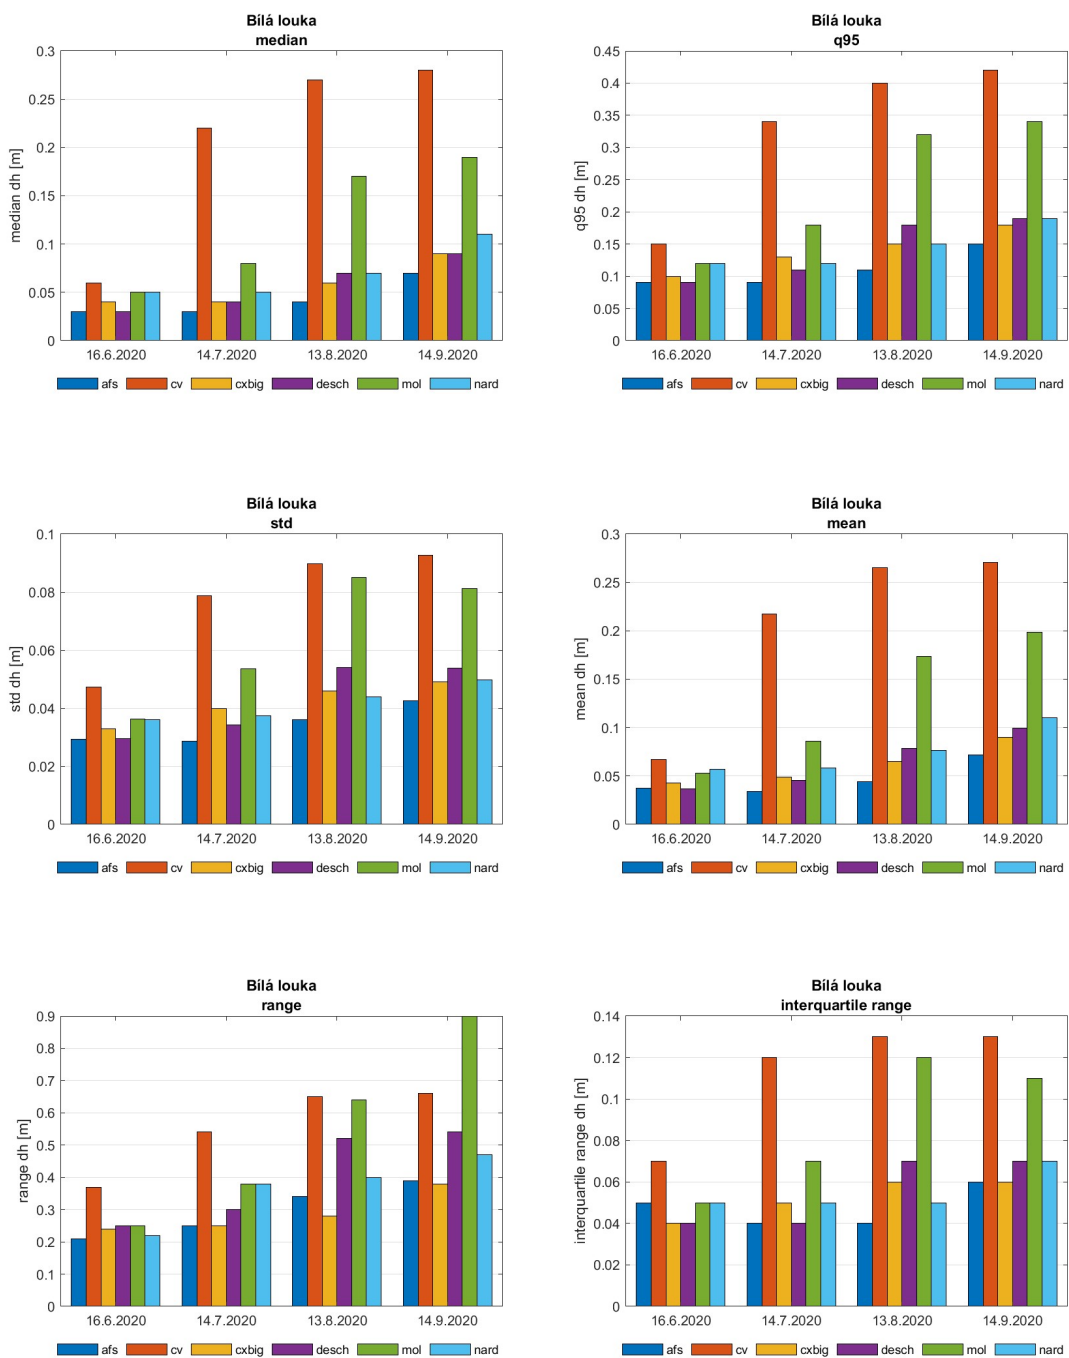
		Bílá louka				Termín LiDARového snímání															
		GNSS/RTK měření 9.6.2020				16.06.2020				14.07.2020				13.08.2020				09.09.2020			
vlíc. bod	-Y [m]	-X [m]	h _{GNSS} [m]	h _{LiDAR} [m]	std [m]	dh [m]	h _{LiDAR} [m]	std [m]	dh [m]	h _{LiDAR} [m]	std [m]	dh [m]	h _{LiDAR} [m]	std [m]	dh [m]	h _{LiDAR} [m]	std [m]	dh [m]			
4001	-644362.81	-983520.68	1447.15	1447.26	0.05	-0.11	1447.26	0.05	-0.11	1447.28	0.05	-0.13	1447.17	0.04	-0.02	1447.17	0.04	-0.02			
4002	-644362.12	-983620.08	1458.59	1458.69	0.11	-0.11	1458.69	0.11	-0.11	1458.67	0.10	-0.09	1458.61	0.09	-0.03	1458.61	0.09	-0.03			
4003	-644463.76	-983620.61	1464.32	1464.46	0.02	-0.14	1464.38	0.07	-0.06	1464.47	0.06	-0.15	1464.39	0.07	-0.07	1464.39	0.07	-0.07			
4004	-644463.81	-983521.14	1450.95	1451.07	0.05	-0.12	1451.03	0.07	-0.08	1451.12	0.08	-0.17	1451.12	0.08	-0.17	1451.12	0.08	-0.17			
4005	-644439.08	-983550.93	1452.95	1453.11	0.06	-0.16	1452.96	0.05	-0.01	1453.09	0.05	-0.14	1452.96	0.06	-0.01	1452.96	0.06	-0.01			
4006	-644414.52	-983575.64	1455.86	1456.01	0.07	-0.15	1456.02	0.07	-0.16	1456.00	0.04	-0.14	1455.87	0.06	-0.01	1455.87	0.06	-0.01			
4007	-644386.42	-983542.63	1450.26	1450.39	0.06	-0.13	1450.36	0.07	-0.11	1450.39	0.06	-0.13	1450.39	0.06	-0.13	1450.39	0.06	-0.13			
4008	-644391.06	-983601.22	1457.33	1457.50	0.06	-0.17	1457.44	0.06	-0.12	1457.48	0.07	-0.15	1457.34	0.07	-0.02	1457.34	0.07	-0.02			
4009	-644443.07	-983592.81	1458.42	1458.60	0.06	-0.18	1458.54	0.07	-0.12	1458.59	0.06	-0.17	1458.48	0.05	-0.06	1458.48	0.05	-0.06			
		medián dh [m]				-0.14			-0.11			-0.14			-0.02			-0.02			
		std dh [m]				0.03			0.04			0.03			0.02			0.02			
		RMSE [m]				0.15			0.10			0.14			0.04			0.04			
		Úpské rašelinště				Termín LiDARového snímání															
		GNSS/RTK měření 9.6.2020				16.06.2020				14.07.2020				13.08.2020				09.09.2020			
vlíc. bod	-Y [m]	-X [m]	h [m]	h [m]	std [m]	dh [m]	h [m]	std [m]	dh [m]	h [m]	std [m]	dh [m]	h [m]	std [m]	dh [m]	h [m]	std [m]	dh [m]			
4001	-643088.20	-983257.79	1429.88	1429.93	0.08	-0.05	1429.94	0.08	-0.06	1429.80	0.06	0.08	1429.89	0.06	-0.01	1429.89	0.06	-0.01			
4002	-643085.60	-983159.99	1431.63	1431.72	0.08	-0.09	1431.82	0.07	-0.19	1431.50	0.07	0.13	1431.69	0.07	-0.06	1431.69	0.07	-0.06			
4003	-642988.15	-983154.29	1431.73	1431.81	0.11	-0.08	1431.82	0.08	-0.09	1431.61	0.06	0.12	1431.74	0.1	-0.01	1431.74	0.1	-0.01			
4004	-642985.67	-983258.17	1431.94	1432.00	0.04	-0.06	1432.03	0.08	-0.09	1431.88	0.08	0.06	1431.97	0.1	-0.03	1431.97	0.1	-0.03			
4005	-643048.85	-983180.36	1431.68	1431.77	0.07	-0.09	1431.78	0.11	-0.10	1431.62	0.06	0.06	1431.75	0.07	-0.07	1431.75	0.07	-0.07			
4006	-643035.64	-983207.77	1431.70	1431.80	0.07	-0.10	1431.76	0.07	-0.06	1431.59	0.07	0.11	1431.74	0.04	-0.04	1431.74	0.04	-0.04			
4007	-643006.83	-983220.39	1431.74	1431.84	0.09	-0.10	1431.82	0.06	-0.08	1431.60	0.11	0.14	1431.83	0.09	-0.09	1431.83	0.09	-0.09			
4008	-643010.44	-983181.60	1431.56	1431.65	0.07	-0.09	1431.64	0.15	-0.08	1431.46	0.12	0.10	1431.64	0.14	-0.08	1431.64	0.14	-0.08			
4009	-643065.21	-983226.08	1430.58	1430.65	0.07	-0.07	1430.69	0.06	-0.11	1430.48	0.06	0.10	1430.61	0.06	-0.03	1430.61	0.06	-0.03			
		medián dh [m]				-0.09			-0.09			0.10			-0.04			-0.04			
		std dh [m]				0.02			0.04			0.03			0.03			0.03			
		RMSE [m]				0.08			0.10			0.10			0.05			0.05			

Příloha 1: Rozdíly ve výšce VLB geodeticky zaměřených a určených z LiDARového snímání pro Bílou louku a Úpské rašelinště.

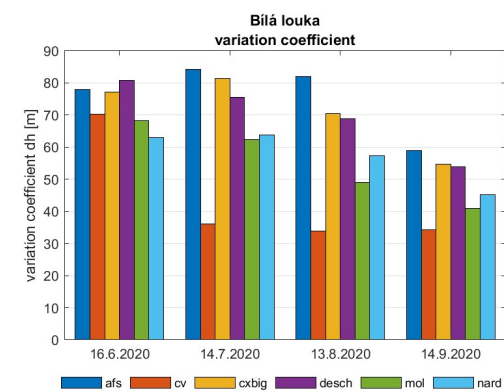
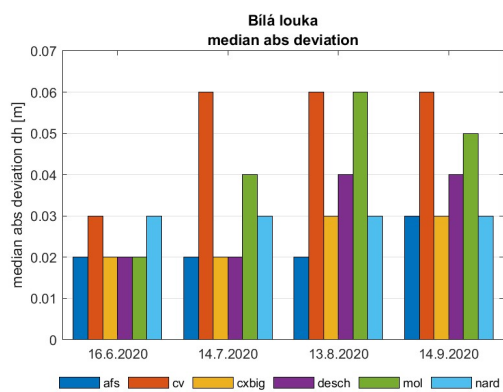
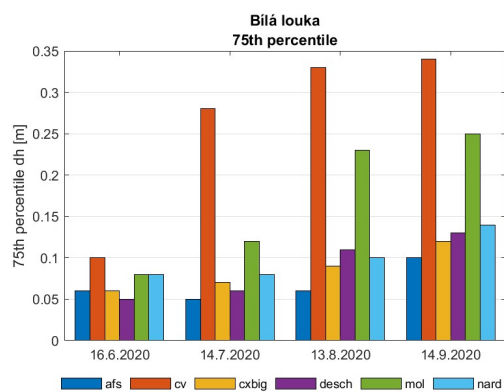
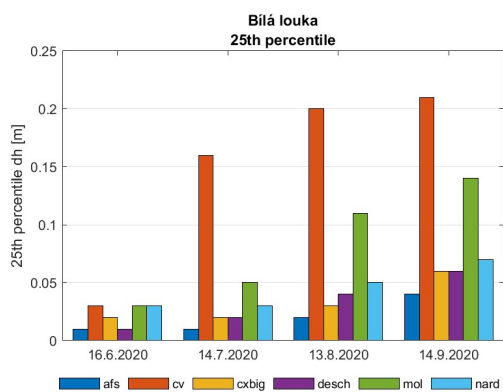

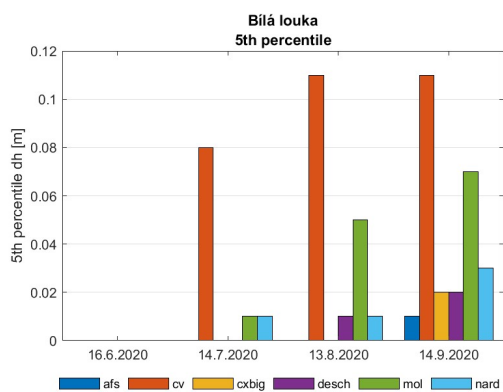
5. percentil (minimum)	hustota vegetace	počet bodů vegetace
10. percentil	interkvantilové rozpětí	poměr bodů <i>ground</i> a vegetace
25. percentil	variační koeficient	průměr
75. percentil	medián	směrodatná odchylka
95. percentil (maximum)	medián absolutní odchylky	textura
<i>canopy relief ratio</i>	počet bodů <i>ground</i>	variační rozpětí

Příloha 2: Seznam širšího výběru strukturních parametrů vegetace.

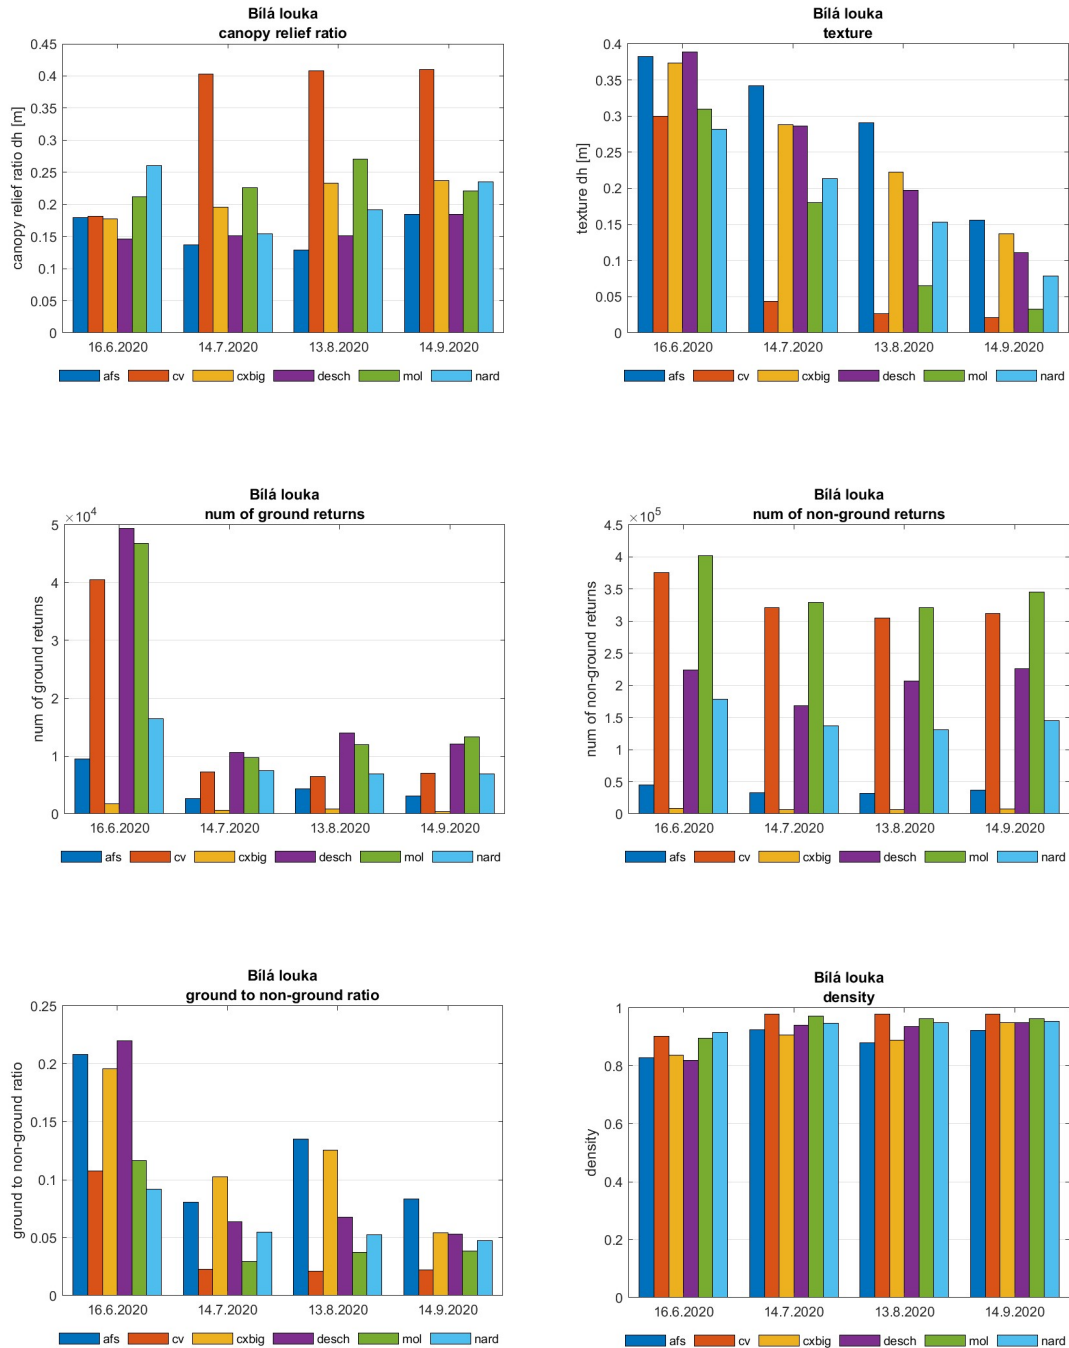
Příloha 3: Statistiky (strukturní parametry) vypočteny nad relativními výškami všech bodů daného druhu.

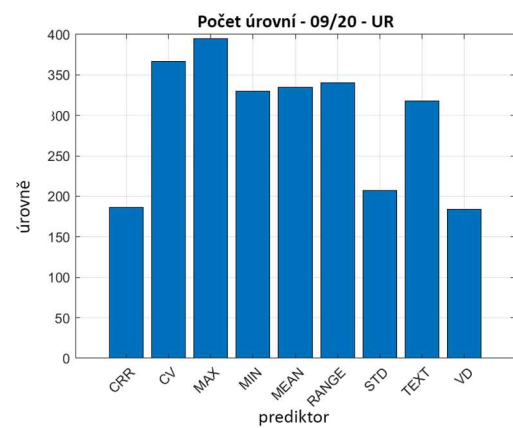
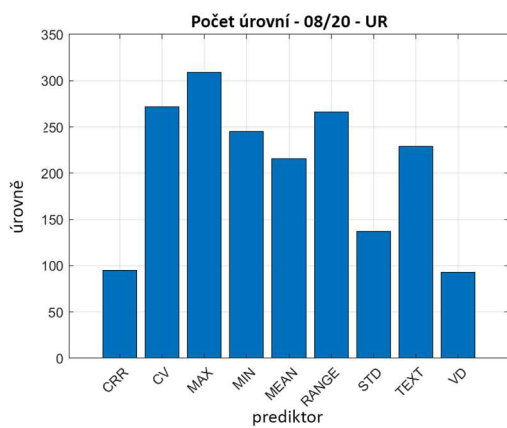








Příloha 3: Statistky (strukturní parametry) vypočteny nad relativními výškami všech bodů daného druhu.


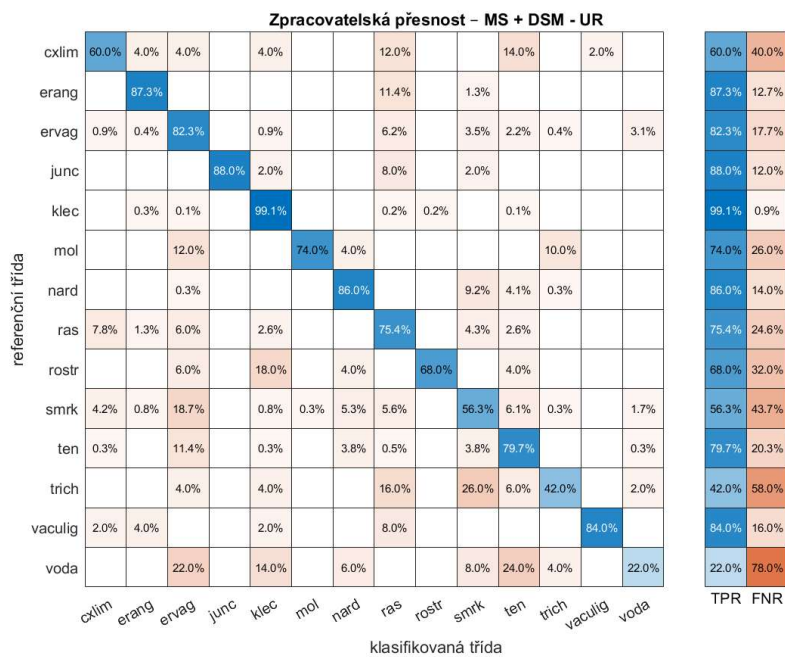



Příloha 3: Statistiky (strukturní parametry) vypočteny nad relativními výškami všech bodů daného druhu.





Příloha 4: Počet úrovní prediktorů.



Příloha 6: Chybové matice pro fúzi MS dat a DMP struktury vegetace.