



Monitoring změn vegetace v krkonošské tundře

Lucie Kupková ⁽¹⁾, Lucie Červená ⁽¹⁾, Markéta Potůčková ⁽¹⁾, Jakub Lysák ⁽¹⁾,
Záboj Hrázský ^(1,2), Stanislav Březina ⁽²⁾, Jana Müllerová ⁽³⁾

(1) Katedra aplikované geoinformatiky a kartografie, Přírodovědecká fakulta, Univerzita Karlova

(2) Správa Krkonošského národního parku

(3) Botanický ústav AV ČR, v, v, i,



FACULTY OF SCIENCE
Charles University



Team of
Image and
Laboratory
Spectroscopy




Motivace

- Reliktní arkto-alpínská tundra v Krkonošském národním parku je kombinací arktické, alpínské a středoevropské flóry a fauny s mnoha ohroženými a endemickými druhy
- Změna hospodaření v posledních 100 letech (pastva a sečení → bezzásahová přírodní zóna NP), depozice dusíku z kyselých dešťů v posledních dekádách 20. století a klimatická změna
→ změny ve složení vegetace:
 - alpínské trávníky s dominancí smilky tuhé (*Nardus stricta*) a výskytem vzácných druhů rostlin jsou ohroženy šířením tří sice původních, ale konkurenčně silných druhů trav: třtiny chloupkaté (*Calamagrostis villosa*), bezkolence modrého (*Molinia caerulea*) a metlice trsnaté (*Deschampsia cespitosa*)
 - expanze borovice kleče a smrku ztepilého
- Systematické sledování změn vegetace (pomocí DPZ) může přinést důležité informace do diskuze o možnosti zavedení vybraných managementových opatření v bezzásahové přírodní zóně národního parku za účelem zachování nejceněnějších společenstev



Kupková a kol. (2017)

- Maximálně 11 tříd:



Sentinel-2A

10 pásem

10-20 m

1 termín

NN


OA = 57 %

Aisa Dual

494 pásem → 40 PCA pásem


1-3 m, 1 termín

SVM, OA = 84 %



Closed alpine grasslands
Nardus stricta stands
 Species-rich vegetation with high cover of forbs
 Subalpine tall grasslands
Calamagrostis villosa stands
Molinia caerulea stands
Deschampsia cespitosa stands
Pinus mugo scrub
 Subalpine *Vaccinium* vegetation
 Alpine heathlands
 Wetlands and peat bogs
 Water areas
 Block fields and anthropogenic areas

Kupková a kol. (2023)



Nardus stricta
Calamagrostis villosa
Molinia caerulea
Deschampsia cespitosa

PlanetScope

4 pásma

3 m

3 termíny

RF

OA = 82 %

UAV MS data



8 pásem

0,03 m

2 termíny

OBIA SVM


OA = 96 %




Nardus stricta
Calamagrostis villosa
Molinia caerulea
Deschampsia cespitosa
Avenella flexuosa
Carex bigelowii
Picea abies

přesnosti:
PA = producer's
(zpracovatelská)
UA = user's
(uživatelská)


Sentinel-2A



Aisa Dual




PlanetScope



multitemporální

UAV MS data



multitemporální



PA = 46,0 %
UA = 54,1 %

PA = 83,7 %
UA = 71,4 %

PA = 87,9 %
UA = 86,0 %

PA = 93,5 %
UA = 93,3 %



PA = 31,8 %
UA = 43,8 %

PA = 55,0 %
UA = 87,3 %

PA = 66,9 %
UA = 97,9 %

PA = 99,6 %
UA = 99,2 %



PA = 15,0 %
UA = 60,0 %

PA = 66,8 %
UA = 75,2 %

PA = 86,6 %
UA = 67,2 %

PA = 98,4 %
UA = 99,2 %



PA = 57,5 %
UA = 26,4 %

PA = 85,1 %
UA = 85,8 %


PA = 76,4 %
UA = 81,8 %

PA = 98,1 %
UA = 93,1 %

Sledované plochy a druhy

- Zhruba 100 x 100 m, různé typy tundry, celkem 34 tříd vegetace (7 až 17 na plochu)

Bílá louka	Luční hora	Úpské rašeliníště	Kar
afs	af	cxlim	bor
cv	afs	erang	ca
cxbig	bor	ervag	cv
desch	desch	junc	desch
mol	klec	klec	erang
nard	nard	mol	klec
smrk	sut	nard	list
	vres	rostr	mokvskal
	vyfuk	smrk	mol
		ten	nard
		trich	niva
		vaculig	pram
		voda	ras
		vres	scirp
			smrk
			sut
			vres





Data a metody

- Snímáno 4x za sezonu (červen-září) po 4 roky (2019 – 2022)
 - Multispektrální data (MS)
 - MS kamera Micasense RedEdge – M®, spektrální pásma: Modrá, zelená, červená, red edge, blízké infračervené
 - RGB kamera Sony A7 ILCE-7 24,3 Mpx; lens- Voigtlander Color – Skopar 21 mm
 - Hyperspektrální data (HS)
 - Headwall Nano-Hyperspec® - řádková kamera, 270 pásem (400 nm – 1000 nm)

→ převzorkováno: velikost pixelu: 9 cm, HS data: 54 pásem

→ multitemporální kompozity
- Botanické mapování s přesným geodetickým GNSS přístrojem:
1/3 ploch využita pro trénování a 2/3 pro validaci klasifikací
- Testované algoritmy klasifikace:
 - Maximum Likelihood (MLC)
 - Support Vector Machine (SVM)
 - Random Forest (RF)
 - Object-based classification – SVM (OBIA)
- Hodnocení přesnosti:
 - Na základě botanických polygonů z terénu vygenerováno 3393* náhodných bodů stratifikovaných dle rozlohy tříd (minimálně však 50 bodů na třídu, ve středu pixelu, nesousedící pixely)
 - Celková přesnost, zpracovatelská a uživatelská přesnost, F1-skóre





* calculated based on reliability of validation accuracy on 2% level (Foody, G.M., Sample size determination for image classification accuracy assessment and comparison, *Int. J. Remote Sens.* 2009, 30, 5273–5291)

Výsledky klasifikací

- Nejlepší pro Bílou louku (se 7 klasifikovanými třídami): OA ~ 90 %
- Nejhorší pro Úpskou jámu (se 17 klasifikovanými třídami): OA ~ 70 %
- Druhy zastoupené více na dané ploše – lepší výsledky


RGBMSS data
MLC, všechny 4 termíny 2019
Celková přesnost: 93,5%



Druh	Nejlepší F1-skóre (v %)			
	F1-score	Data	termíny	klasifikátor
NS	94.7	MS	7,8	OBIA
CV	99.4	MS	6,7,8	OBIA
MC	99.2	MS	7,8	OBIA
DC	96.3	HS	6,7,8	OBIA
AF	59	MS	7,8	OBIA
CB	45.6	HS	6,7,8	OBIA

Výsledky klasifikací



- Dva termíny výrazně lepší přesnost než pouze jeden, tři už nepřinesou velký skok v celkové přesnosti



Porovnání celkových přesností různých klasifikátorů pro Bílou louku na základě 1 snímku resp. kombinace 2 či 3 snímků pro MS i HS data


Celkové přesnosti klasifikací HS dat pro Bílou louku v průběhu všech sledovaných let a klasifikátory Maximum Likelihood a Random Forest (zelená nejlepší výsledky, červená nejhorší)

termín(y)	OA 2019	OA 2020	OA 2021	OA 2022
MLC 06-07-08-09	92.37	90.83	89.68	
MLC 06-07-08	92.51	91.07	88.98	87.89
MLC 06-07-09	91.95	90.42	88.98	
MLC 06-08-09		90.89	90.19	
MLC 06-08	89.83	90.19	89.66	87.06
MLC 07	87.30	80.61	70.14	69.91
MLC 08	82.61	81.17	81.90	78.10
RF 06-07-08-09	92.99	93.02	89.30	
RF 06-07-08	92.31	93.49	85.50	85.91
RF 06-07-09	93.02	91.92		
RF 06-08-09			90.89	
RF 06-08	92.37	92.63	87.68	83.44
RF 07	87.71	84.56	76.98	77.66
RF 08	86.24	85.12	80.65	77.80



Výsledky klasifikací

- Multispektrální vs. Hyperspektrální data dosahují velmi podobných výsledků, klíčové je zde prostorové rozlišení v řádu centimetrů
- Problémy s osvětlením v datech – nemusí se objevit v ukazatelích přesnosti, ale v klasifikaci jsou viditelné, ovlivní pak změnové mapy



třída	PA v %	UA v %
afs	38,58	52,69
cv	94,55	82,79
cxbig	2	100
desch	80,16	85,16
mol	86,76	79,82
nard	49,89	61,94
smrk	52	100

OA = 79 %

Hodnocení pomalých změn vegetace v tundře

- Skutečná změna vs. chyby/šum/nepřesnosti v datech (klasifikaci)
- Možné zdroje chyb speciálně pro data z dronu s velmi vysokým prostorovým rozlišením:
 - potíže s absolutní polohovou přesností podkladových dat a z toho vyplývající omezení přesnosti překrytí (report o dosažené přesnosti při zpracování ortofota)
 - nepřesnost klasifikace (metriky hodnotící přesnost klasifikace)
 - sezónní růst vegetace vs. mezisezónní dlouhodobý trend (pečlivá volba strategie doby snímání)
 - problémy vyplývající z geometrie/výšky objektů při pořizování dat s vysokým prostorovým rozlišením, mimo jiné v závislosti na směru větru se může dostatečně vysoká tráva polohově posunout, v datech se vyskytují stíny pokaždé jinde apod.
- Aby byla změna spolehlivě zjistitelná, měla by být dostatečně velká
→ nutný časový odstup

Přístupy k hodnocení změn

- naivní přístup (překrytí dvou klasifikací)
 - Příliš mnoho „změn“ (převážně okolo hranic jednotlivých tříd)
 - Vylepšení: generalizace výsledných rastrů s klasifikacemi (majority filter, aplikace morfologických operátorů,...)
- využití statistické informace podle Olofssona a kol. (2013, 2014)*
 - Informace odhadu plochy dané třídy ve tvaru (plocha $\pm$ spolehlivost)
 - Odpovídá na otázku změny pro konkrétní třídu: kolik přibýlo / ubylo / zůstalo nezměněno, ale neříká, kde k tomu došlo
- kombinace více klasifikací
 - Průměrování různých metod klasifikace (případně stejných metod klasifikace s různými parametry) z určitého období
 - průnik / shoda: výsledná třída se jako výstup na daném místě objeví pouze tehdy, pokud se na tomto místě vyskytuje ve všech klasifikacích, které byly provedeny
 - částečná shoda: výsledná třída je taková, která se objeví alespoň v určitém procentu klasifikací, které byly provedeny (například u jejich nadpolovičního počtu)
 - vážené průměrování: pixel s danou třídou dostane váhu podle F1-skóre. Výsledkem je pak pro jednu danou klasifikaci mapa pravděpodobnosti. Tyto pravděpodobnosti lze pak pro jednotlivé klasifikace sčítat nebo průměrovat. Výsledný obraz se pak opražuje (například hodnotou 50 %), čímž dostaneme oblasti s výskytem dané třídy.
 - výsledkem kombinace více klasifikací je (nová) klasifikace
→ potenciálně robustnější spočítání změn rozlohy tříd
- kombinace více klasifikací se zohledněním polohové nejistoty
 - postup stejný jako v předchozím případě, ale snaží se řešit také polohovou nejistotu snímku → fuzzy definice polohy třídy

* Olofsson et al. (2013): Making Better Use of Accuracy Data in Land Change Studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. Remote Sensing of Environment, 129:122–131. Olofsson et al. (2014): Good Practices for Estimating Area and Assessing Accuracy of Land Change. Remote Sensing of Environment, 148:42–57.


Změna v rozloze třtiny chloupkaté na Bílé louce 2019 – 2022

Mapa změn

lokality: BL

třída: cv

	vymapováno [m²]	uživatel. přesnost	zpracovatel. přesnost	odhad Olofsson [m²]	int. 95% spolehl. [m²]
data1: MT_2019_07_10_2019_08_14_BL_MLC	1844.89	98.72	97.67	1934.85	55.65
data2: MT_2022_07_13_2022_08_11_BL_MLC	2250.76	94.97	90.08	2636.94	97.53



změna mezi data1 a data2:

■	přírůstek	645 m²
■	stabilní	1661 m²
■	úbytek	228 m²

0 10 20 m


podkladové ortofoto: 2022_08_11_BL_MSSRGB_3cm_envi.tif

Mapa změn

lokality: BL

třída: cv

	vymapováno [m²]	uživatel. přesnost	zpracovatel. přesnost	odhad Olofsson [m²]	int. 95% spolehl. [m²]
data1: ens_MT_2019_07_10_2019_08_14_BL	1741.37	99.60	96.40	2031.25	90.45
data2: ens_MT_2022_07_13_2022_08_11_BL	2102.70	97.37	93.58	2422.47	88.84




změna mezi data1 a data2:

■	přírůstek	560 m²
■	stabilní	1541 m²
■	úbytek	199 m²

0 10 20 m

podkladové ortofoto: 2022_08_11_BL_MSSRGB_3cm_envi.tif



Děkujeme za pozornost!



- KUPKOVÁ, L., ČERVENÁ, L., POTŮČKOVÁ, M., LYSÁK, J., ROUBALOVÁ, M., HRÁZSKÝ, Z., BŘEZINA, S., EPSTEIN, H. E., MÜLLEROVÁ, J. (2023): Towards reliable monitoring of grass species in nature conservation: Evaluation of the potential of UAV and PlanetScope multi-temporal data in the Central European tundra. Remote Sensing of Environment 294, 2023.
<https://doi.org/10.1016/j.rse.2023.113645>
- 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, DOI: <http://doi.org/10.1080/22797254.2017.1274573>