



CHARLES UNIVERSITY
Faculty of Science



Přírodovědecká fakulta UK

Ústav výzkumu globální
změny AV ČR

Ústav pro hydrodynamiku
AV ČR

Projekt TAČR SS05010124

**Hodnocení vlivu změn krajinného pokryvu na lokální hydrologii a klima
v Krkonošském národním parku s využitím dálkového průzkumu Země
a hydrologického modelování**

Dílčí metodika využití družicových dat DPZ
pro monitoring změny krajinného pokryvu
s důrazem na hodnocení změn
lesních porostů

Autoři: Markéta Potůčková, Alex Šrollerů, Lucie Červená, Jakub Dvořák, Lucie Kupková

Přírodovědecká fakulta UK, prosinec 2023

Obsah

Úvod	2
Cíle metodiky	2
Využitá data	2
Navržené metody	3
Předzpracování dat: tvorba bezoblačných mozaik.....	4
Legenda	6
Klasifikace	7
Postklasifikační úpravy	9
Hodnocení přesnosti klasifikace	13
Integrated forest z-score a index disturbance	14
Analýzy časové řady	15
Příklady analýzy časové řady výstupů klasifikace	15
Příklady analýzy časové řady vybraných indexů.....	16
Závěr	17
Literatura a zdroje	17
Přílohy.....	19
Příloha I: Vliv monotemporální filtrace na počet změn klasifikační třídy	19
Příloha II: Mapy krajinného pokryvu 2010 a 2018	20
Příloha III: Stabilní plochy krajinného pokryvu v letech 1985–2022	21
Příloha IV: Změny lesních porostů na základě klasifikace dat Landsat 1985–2022	22
Příloha V: Porovnání krajinného pokryvu v letech 1985 a 2022	23
Příloha VI: Trend indexu disturbance 2002–2022	24
Příloha VII: Nejvýznamnější změna IFZ mezi roky 1985–2022	25

Úvod

Otevřený přístup k družicovým datům umožňuje sledování změn zemského povrchu v široké škále měřítek, tj. od globálního pohledu po lokální studie (prostorové rozlišení v řádu km po jednotky metrů) a časových intervalů (desítky let vs. pozorování na denní bázi). Pro naplnění cílů projektu TAČR SS05010124 vznikla potřeba vytvořit datové vrstvy krajinného pokryvu ve sledovaných povodích horní Úpy a horní Čisté od počátku 90. let 20. století s vysokým prostorovým i časovým rozlišením. Tyto vrstvy jsou důležitým vstupem pro modelování vlivu změn krajinného pokryvu na hydrologické poměry. Vedle tříd krajinného pokryvu družicová data umožňují na základě spektrálních charakteristik odvodit indikátory celkového stavu lesní vegetace a jejích změn souvisejících s přírodními událostmi typu vichřice, námrazy či napadení škůdci, ale také s její následující obnovou.

Cíle metodiky

Vytvořená metodika popisuje postupy zpracování volně dostupných družicových dat vedoucí k vytvoření časové řady datových vrstev s prostorovým rozlišením 30 m obsahujících:

1. klasifikaci krajinného pokryvu dle navržené legendy,
2. indikátorů zdravotního stavu lesa založených na znalosti spektrální odezvy lesní vegetace.

Dále ukazuje možnosti analýzy a interpretace vytvořených časových řad. Využitelnost metodiky a konkrétní implementace jsou dokumentovány na příkladu území povodí horní Úpy a horní Čisté.

Využitá data

Metodika je postavena na zpracování volně dostupných družicových dat vysokého prostorového rozlišení programů Landsat (Landsat, 2023) a Copernicus (Copernicus, 2023). Specificky se zaměřuje na multispektrální snímky pokrývající viditelné (RGB), blízké (NIR) a střední infračervené (SWIR) pásmo pořízené senzory uvedenými v tabulce 1.

Tabulka 1. Přehled družicových dat využitých pro tvorbu metodiky

Družice	Senzor	Prostorové rozlišení	Použitá spektrální pásma*	Dostupnost
Landsat 5	Thematic Mapper (TM)	30 m	RGB (3, 2, 1) NIR (4)	1984–2013
Landsat 7	Enhanced Thematic Mapper + (ETM+)		SWIR (5, 7)	1999–2024
Landsat 8	Operational Land Imager (OLI)		RGB (4, 3, 2) NIR (5), SWIR (6, 7)	od 2013
Sentinel-2	Multi-spectral Instrument (MSI)	10 m	RGB (4, 3, 2), NIR (8)	od 2015
		20 m	RedEdge (5, 6, 7), NIR (8A), SWIR (11, 12)	

* vlnové délky jednotlivých spektrálních pásem jsou dostupné z webových stránek příslušných senzorů [TM](#), [ETM+](#), [OLI](#) a [MSI](#).

Ke sběru trénovacích dat pro řízenou klasifikaci družicových snímků byla použita ortofota dostupná z webové mapové služby Českého úřadu zeměměřického a katastrálního (ČÚZK, 2023) a Správy KRNAP (KRNAP, 2023). Jako doplňková data pro klasifikaci nebo vývoj metodiky byl využit digitální model terénu SRTM (USGS, 2023), normalizovaný digitální model povrchu (nDSM) z let 2022 (LiDAR) a 2018 (letecké měřické snímky) a vrstva lesních dřevin webové mapové služby Ústavu pro hospodářskou úpravu lesů (ÚHÚL, 2023) (tabulka 2).

Tabulka 2. Přehled doplňkových dat využívaných pro tvorbu metodiky

Data	Rok pořízení	Rozlišení*	Zdroj
Ortofoto	1997–2000	0,50 m	ČÚZK, KRNP
	2001–2008	0,50 m	
	2009–2015	0,25 m	
	2016–2022	0,20 m	
nDSM	2018	1 m ⁺	ÚHÚL
	2022	1 m ⁺	TAČR SS05010124
Lesní dřeviny	2017, 2019, 2022	-	ÚHÚL
SRTM DTM	2000	30 m	USGS

* v letech 1997 a 2000 snímky panchromatické, dále RGB, v roce 2022 dostupné i CIR snímky

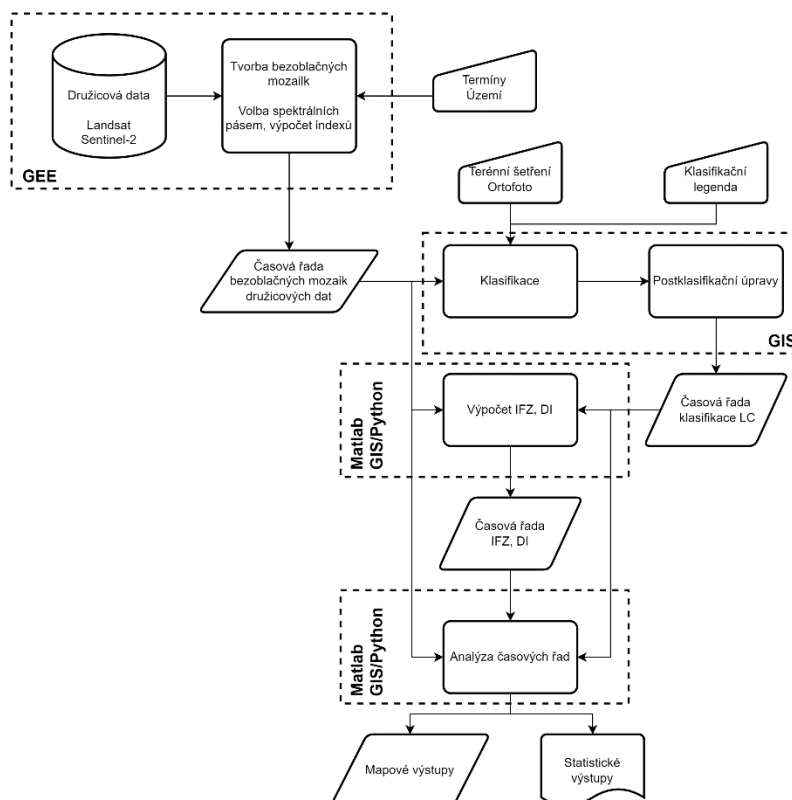
+ pro účel vývoje metodiky data byla data převzorkována na 10 m

V roce 2022 proběhlo terénní šetření, při němž byla sbírána validační data zejména pro kategorie přechodová stadia lesa, listnatý a smíšený les (viz sekce [Legenda](#)).

Navržené metody

Předkládaná metodika v obecné rovině sestává ze čtyř základních kroků, a to výběr a předzpracování časové řady družicových dat, klasifikace, výpočet spektrálních indexů, analýza a interpretace časových řad. Zpracovatelský postup včetně všech použitých vstupů je schematicky znázorněn na obrázku 1. Pro implementaci byly využity softwarové nástroje Google Earth Engine (GEE), ArcGIS Desktop a ArcGIS Pro. Pro výpočet spektrálních indexů a některé z analýz byly vytvořeny skripty pro MATLAB a Python.

Obrázek 1. Navržený postup zpracování časové řady družicových dat za účelem klasifikace krajinného pokryvu a analýzy stavu lesních porostů. Softwaru Google Earth Engine (GEE), ArcGIS Desktop a ArcGIS Pro a skripty pro MATLAB a Python byly použity v provedené implementaci metodiky.



Předzpracování dat: tvorba bezoblačných mozaik

Cílem předzpracování dat je vytvořit radiometricky homogenní časovou řadu snímků souvisle pokrývajících zájmové území. Jelikož se předpokládá přímé porovnávání radiometrických hodnot v časové řadě či z nich odvozených indexů, je vhodnější používat snímky po geometrické a radiometrické korekci (tzv. úroveň L2) obsahující hodnoty odrazivosti na zemském povrchu.

Změny krajinného pokryvu, resp. vývoj lesního porostu, mohou být sledovány s různou frekvencí a v různě dlouhých časových intervalech. Navržená metodika směřuje ke sledování meziročních změn. Z důvodu omezení detekce změn způsobených nikoliv meziroční změnou vegetace, ale změnou jejich fenologické fáze, je třeba vybrat snímky přibližně ze stejného dne v roce, resp. z téhož úseku vegetačního cyklu.

Zásadním problémem při zpracování optických dat je přítomnost oblačnosti, která často znemožňuje použití celé scény družicových dat ve zvoleném termínu. Při sledování meziročních změn lesní vegetace se proto přistupuje k tvorbě mozaik složených z pixelů bez oblačnosti, které ale pocházejí z různých snímků stanoveného časového intervalu (např. 1.7. – 31.8. daného roku). Pro výběr validních pixelů lze využít tzv. „pásmo kvality“ L2 produktů (dále QB), v němž jsou na základě klasifikace označeny pixely s oblačností, pixely zastíněné oblačností, pixely mimo rozsah radiometru atd. (Landsat QA, 2023; Sentinel-2 Level 2A, 2023).

V rámci tvorby metodiky byly testovány dva přístupy. Oba pro daný rok nejprve vyberou dostupné snímky dle zadaného časového intervalu (rozsah DOY). První přístup pak pro každý pixel vybere na základě QB validní hodnoty a do výsledné mozaiky dosadí jejich medián či jinak zvolený percentil. Druhý přístup z validních pixelů vybere ten, který časově je nejbližší vybranému dni. Navíc uplatňuje váhu dle vzdálenosti od nevalidních pixelů. V případě, že není možné bezoblačnou mozaiku v daném rozsahu DOY pro daný rok vytvořit, jsou doplněny snímky z předchozího a následujícího roku.

Implementace

Přístup využívající medián (či zvolený percentil) **validních pixelů** byl implementován v prostředí GEE na datech Landsat z let 1985–2022 a Sentinel-2 v časovém rozmezí 2017–2022 (spodní hranice je dána možnostmi GEE v době implementace na podzim 2022). Primárně byla použita data odrazivosti na zemském povrchu (L2). Data bez atmosférické korekce (L1) byla použita pro výpočet Tasseled cap transformace (viz níže).

V rámci každé vegetační sezóny (červen–září, DOY 150–270) byly v dostupných scénách Landsat/Sentinel-2 radiometrické hodnoty každého pixelu uspořádány vzestupně s označenými nevalidními hodnotami na konci řady. Následně byl zvolen percentil (blízký mediánu), který stanovil hodnotu vstupující do vytvářeného kompozitu. V případě Landsatu 5 byla pro některé roky nutná kombinace s daty Landsat 7. Roky, kde bezoblačného kompozitu nebylo možné v zájmovém území dosáhnout, byly vynechány, resp. nahrazeny dvou či tříletým kompozitem, v případě delší než roční mezery. Přehled o vytvořené časové řadě, použitých datech a parametrech je v tabulce 3. Ukázka podílu validních pixelů v časové řadě pokrývajících vegetační sezónu vybraných let je na obrázku 2.



Výsledný kompozit obsahoval vybraná původní spektrální pásma daného senzoru a vypočtené spektrální indexy vhodné pro sledování stavu vegetace – NDVI (Normalized Difference Vegetation Index), NDII (Normalised Difference Infrared Index), NBR2 (Normalised Burn Ratio) a hodnoty Greenness, Brightness a Wetness Tasseled Cap transformace (TCG, TCB, TCW). Pro výpočet TC byly použity snímky Landsat a Sentinel-2 obsahující odrazivost na povrchu atmosféry a koeficienty dle Crist a Cicone (1984) pro Landsat 5, Baig et al. (2014) pro Landsat 8 a Shi, Xu (2019) pro Sentinel-2. Jako další

vrstva byly přidány výšky z modelu SRTM. Struktura a rozsah výsledných dat (ve formátu tif, souřadnicový systém WGS 84/UTM 33N, kód EPSG 32633) je na obrázku 3.

Tabulka 3. Shrnutí časových horizontů, v nichž bylo možné vyhotovit roční bezoblačné kompozity družicových dat, resp. souvislé datové vrstvy krajinného pokryvu, a v nichž byla dostupná doplňková data pro klasifikaci (označeno křížky). Oranžové podbarvení označuje období, kdy byl použit dvouletý nebo tříletý kompozit (pouze ze snímků vegetační sezóny). V letech 1999 až 2002 a v roce 2006 byly kombinovány scény senzorů TM (Landsat 5) a ETM+ (Landsat 7). Percentil L5/L8 označuje percentil ve vzestupně uspořádané řadě radiometrických hodnot pixelu zvolený pro vytvoření bezoblačného kompozitu z dat Landsat. Pro Sentinel-2 byl použit vždy medián (percentil 50). Dolní polovina tabulky shrnuje datové vstupy použité pro sběr trénovacích a validačních množin.

		Datové vstupy pro analýzu krajinného pokryvu																																						
rok		1985	1986	1987	1988	1989	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	
Družicová data	L5	x	x		x		x	x	x		x	x		x		x	x	x	x	x	x	x	x			x	x	x												
	L7															x	x	x	x				x																	
	L8																																							
	S-2																																							
Percentil L5/L8		40	40		40		40	40		50		40	40		40		60	40	40	60	40	40	40	50	40			40	40	40										
Ortofoto															x		x	x			x	x						x	x											x
nDSM																																								x
Terénní šetření																																								x
Lesní dřeviny																																							x	

Obrázek 2. Podíl validních pixelů (bez oblačnosti, stínů) ve snímcích Landsat seřazených vzestupně dle podílu oblačnosti v zájmovém území pro vegetační sezónu 2014 (bezoblačný kompozit se nepodařilo vytvořit) a sezónu 2022.



Obrázek 3. Struktura vrstev výsledných bezoblačných kompozitů a rozsah jejich hodnot.


Poradi spektrálních pasem ve výsledných kompozitech:
L5+L7 - B1, B2, B3, B4, B5, B7, TCB, TCG, TCW, NDVI, NDII, NBR2, SRTM
L8 - B2, B3, B4, B5, B6, B7, TCB, TCG, TCW, NDVI, NDII, NBR2, SRTM
S2 - B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12, TCB, TCG, TCW, NDVI, NDII, NBR2, SRTM

Hodnoty v pásmech:

B* reflectance * 10000 [0, 10000]
TCB, TCG, TCW Taseled cap * 10000 [0, 10000]
NDVI, NDII, NBR2 index * 10000 [-10000, 10000]
SRTM n. vyska v metrech [~550, ~1600]


Postup založený na nejmenším časovém odstupu od daného DOY byl implementován v softwaru R. Byl použit na časovou řadu scén Landsat v období 1985–2022. Cílový DOY byl optimalizován na snímek s nejmenším zastoupením oblačnosti v období červen–září (DOY 150–270). Součástí řešení je grafické znázornění podílu a prostorového zastoupení snímků tvořících mozaiku (obrázek 4).

Obrázek 4. Složení bezoblačné mozaiky dle DOY a roku („year“) z dat Landsat 8 pro rok 2019 a 2021 (nutný kompozit ze 3 let).



Nevýhodou implementace tohoto druhého postupu oproti využití GEE je nutnost stažení všech scén na lokální disk. **Na základě vizuálního porovnání výsledných mozaik bylo rozhodnuto využít výstup metody využívající medián/percentil validních pixelů** (obrázek 5). Vytvořené bezoblačné kompozity jsou k nahlédnutí v aplikaci na GEE (GEE_vizualizace, 2023).

Obrázek 5. Vizuální porovnání bezoblačné mozaiky odvozené na základě mediánu (vlevo) a časového odstupu od zvoleného DOY (vpravo – viditelné artefakty po odmaskování oblačnosti).



Legenda

Návrh tříd pro klasifikaci vychází z požadavků legendy pro hydrologický model SWAT. Tato legenda do jisté míry vychází z land cover databáze CORINE. Na základě neřízené klasifikace provedené na datech Landsat 8 a Sentinel-2 v roce 2022 a 2018 bylo rozhodnuto o rozdělení třídy „jehličnatý les“ na „zapojený“ a „nezapojený“ (prosvítající půdní pokryv alespoň z 25 %) a „jehličnatý les odumřelý“. Ve třídě „kleč“ byla vyčleněna „kleč s příměsí smrku/jeřábu“, která se jinak výrazně mísila se třídou „přechodová stadia lesa a křoviny“. Tyto třídy lze rozlišit *in-situ* a z barevných ortofot, ale je problematické je vizuálně rozpoznat v případech, kdy trénovací množiny pro klasifikaci jsou definovány pouze na základě dat Landsat. Tam, kde bylo možné pro tyto třídy trénovací množiny vytvořit, byly klasifikovány, ale v rámci zachování jednotné klasifikační legendy v celé časové řadě byly s výjimkou kategorie „jehličnatý les odumřelý“ následně zase spojeny do tříd „jehličnatý les“ a „kosodřevina“.

Výsledná klasifikační legenda je tvořena následujícími třídami:

Kód třídy	Třída krajinného pokryvu
100	Zástavba a komunikace
200	Louky (včetně přírodních), pastviny
310	Listnatý les
320	Jehličnatý les
323	Jehličnatý les odumřelý
330	Smíšený les
340	Přechodová stadia lesa a křoviny
350	Holiny, oblasti s nízkou vegetací
400	Kosodřevina
500	Rašeliniště
600	Skály, kamenná moře
700	Vodní plochy a toky

Klasifikace

Jako příznaky pro klasifikaci byly použity hodnoty odrazivosti v dílčích spektrálních pásmech a spektrální indexy, jak jsou uvedeny na obrázku 3. V první fázi byl aplikován neřízený přístup, který sice vymežil spektrálně homogenní plochy, ale jejich přiřazení do požadované klasifikační legendy se ukázalo být problematické. Z metod řízené klasifikace byl na základě předchozích zkušeností (Kupková et al., 2023) zvolen přístup „náhodných stromů“ (Random Forest, RF) z následujících důvodů. Jedná se o neparametrický, robustní klasifikátor, do něhož mohou vstupovat data rozdílných škál hodnot (v našem případě indexy, odrazivost, nadmořské výšky), podává informaci o významu jednotlivých příznaků (prediktorů) v klasifikaci, požadavek na množství trénovacích dat je nižší než v případě konvolučních neuronových sítí.

Základní metodou pro sběr trénovacích dat byla vizuální interpretace barevných (RGB, popř. CIR) ortofot, jejichž rozlišení (0,2 až 0,5 m) umožňuje spolehlivě určit výše stanovené třídy krajinného pokryvu. V aktuálním časovém horizontu je žádoucí hůře interpretovatelné oblasti doplnit terénním šetřením. nDSM je vhodnou datovou vrstvou pro odlišení růstových stadií vegetace a stromové vegetace na horní hranici lesa. V dostupné datové sadě byla k dispozici pouze v letech 2018 a 2022 a byla použita pro vymezení tříd „přechodová stadia lesa“ a „jehličnaté lesy“. Digitální model terénu STRM byl využit z důvodu výškové členitosti území a byl důležitý pro rozpoznání třídy „jehličnatý les“ na horní hranici lesa. Vizuální interpretace je časově náročná, nicméně se v případě existence ortofot ukázala být spolehlivější metodou oproti přenesení natrénovaného klasifikátoru mezi dílčími lety, což je z teoretického hlediska relevantní postup s ohledem na radiometricky korigovaná data.

Implementace


Trénovací data pro všechny třídy byla nejprve zkušebně vytvořena nad ortofoty z let 2022 a 2018. Jako doplňková data pro trénování byl použit nDSM pro odlišení mladého lesa (do 5 m, kategorie 340) a vrstva lesních dřevin webové mapové služby ÚHÚL. V roce 2022 navíc proběhlo terénní šetření pro upřesnění některých kategorií (zejména přechodová stadia lesa).

Sběr trénovacích množin od roku 1997 proběhl vizuální interpretací dostupných ortofot v kombinaci, popř. kontrolou nad daty Landsat. U snímků z let 1985, 1988, 1991 a 1994 byly trénovací množiny sbírány jen interpretací snímků Landsat. V letech 1986, 1990 a 1992 byl přenesen klasifikátor z nejbližšího roku. Třída zástavba a komunikace byla vygenerována z Open Street Map a použita pro

všechny časové horizonty. Stejně tak třída vodní plochy a toky, kterou ve 30 m rozlišení dat Landsat tvoří jen několik pixelů, byla zvektorizována nad ortofotem a vložena do výsledné klasifikace.

Pro klasifikaci byl použit algoritmus Random Trees (implementace v ArcGIS Desktop v10). Nad vytvořenými bezoblačnými kompozity Landsat 8 a Sentinel-2 s přidanými vrstvami spektrálních indexů byl sledován význam jednotlivých příznaků pro klasifikaci. Z grafů na obrázku 6 stojí za zmínku význam nadmořské výšky terénu jako důležitého příznaku provedené klasifikace. Dále byly testovány parametry klasifikátoru, které byly stanoveny na 300 stromů (number of trees) a maximální hloubku stromu (max tree depth) 60.

Obrázek 6. Důležitost spektrálních pásem, odvozených indexů a nadmořské výšky jako příznaků pro klasifikaci Random Trees pro data Landsat 8 a Sentinel-2, rok 2022.




V dalším kroku byla zkoumána přenositelnost klasifikátoru na další časový horizont (relevantní předpoklad pro data úrovně L2 pořízená z téhož senzoru). Z tabulky 4 vyplývá, že při použití klasifikátoru trénovaného v jiném časovém horizontu došlo v případě dat Landsat 8 k poklesu přesnosti klasifikace o 4 % a v případě dat Sentinel-2 o 6 %. Vzhledem k objemu manuální práce při úpravě trénovacích množin mezi jednotlivými časovými horizonty a nepřesnostem v definici trénovacích ploch pouze nad daty Landsat, byl přenos klasifikátoru použit pouze experimentálně na roky 1986, 1990 a 1992.

Tabulka 4. Porovnání přesnosti klasifikace v letech 2022 a 2018. V případě roku 2018 je porovnávána přesnost při použití klasifikátoru natrénovaného na trénovací množině vytvořené nad ortofotem z roku 2022 (klasifikátor 2022) a na trénovací množině vytvořené nad ortofotem z roku 2018 (klasifikátor 2018). V obou případech je použita stejná sada 1 500 validačních bodů.

	Celková přesnost klasifikace		
	2022	2018	
		klasifikátor 2022	klasifikátor 2018
Landsat 8	0,75	0,68	0,72
Sentinel-2	0,81	0,74	0,80

Při tvorbě trénovacích dat tříd listnatého, smíšeného a jehličnatého lesa a přechodových stádií lesa byla v letech 2018 a 2022 brána v úvahu výška vegetace z nDSM, kdy do přechodových stádií lesa byl zahrnut porost pouze do 5 m výšky. V jiných letech nebyla data nDSM k dispozici. Obrázek 7 ukazuje četnosti výšek porostu (nDSM) ve vybraných třídách klasifikace z dat Sentinel-2 v roce 2022. Z grafu je patrné, že třídy klasifikované pouze na základě spektrálních vlastností vegetace a nadmořské (nikoliv relativní) výšky do značné míry odpovídají výškové struktuře porostu.

Obrázek 7. Četnost výšky vegetace ve čtyřech vybraných třídách krajinného pokryvu klasifikovaných z dat Sentinel-2 v roce 2022. Výška vegetace byla odvozena z nDSM o hustotě 1bod/m².



Postklasifikační úpravy

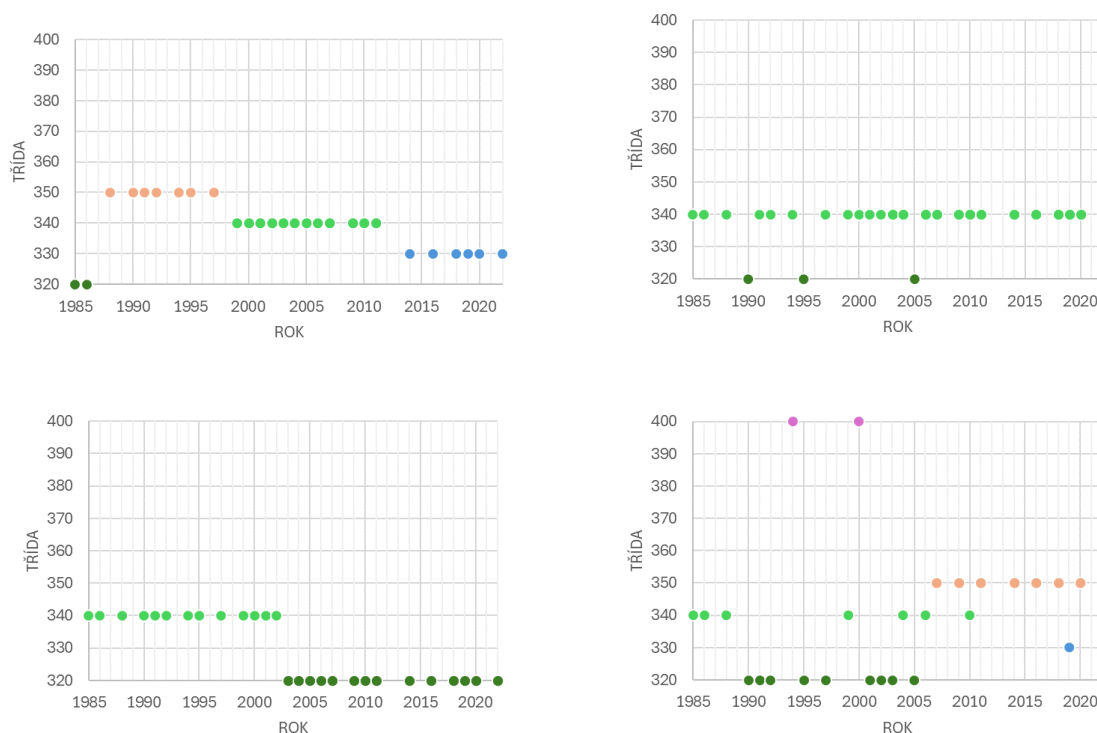
Výsledek klasifikace, která při zařazení do tříd pracuje s dílčími pixely, a nikoliv většími plošnými celky sdružující pixely sobě radiometricky podobné (objektový přístup), je zatížen náhodným šumem způsobeným vstupními daty (radiometrické hodnoty, definice trénovacích množin). Postklasifikační úpravy lze provést ve dvou krocích:

- a) v každém časovém řezu zvlášť použitím majoritního filtru a stanovením minimální mapovací jednotky. Tento krok vede k odstranění osamocených pixelů uvnitř nebo na okraji homogenních oblastí.
- b) vyhlazením časové řady, tj. odstraněním nereálných změn krajinného pokryvu v rámci časové řady.

V případě majoritního filtru je hodnota pixelu nahrazena, pokud jsou splněny podmínky „většiny“ ve zvoleném okolí a pixely tvořící většinu musí být vzájemně propojeny přes hranu (4 sousedé) nebo vrchol (8 sousedů) se středem filtru. Minimální mapovací jednotka je volena vzhledem k velikosti objektů ve skutečnosti a velikosti pixelu. Její minimální hodnota se obvykle volí 1x2 nebo 2x2 pixely.

Při vyhlazení časové řady se mění hodnota pixelu v daném roce na základě porovnání s jeho hodnotou v letech okolních dle zadaných pravidel, které respektují reálné možnosti změn krajinného pokryvu v čase. Obrázek 8 ilustruje příklady, kdy lze změny v časové řadě považovat za skutečné a kdy se jedná o nepravděpodobné změny, které budou v rámci postklasifikačních úprav vyhlazeny.

Obrázek 8. Příklady pravděpodobných změn (vlevo) a nepravděpodobných změn (vpravo) v časové řadě krajinného pokryvu. Změny v grafech vpravo budou identifikovány jako falešné a budou vyhlazeny v rámci postklasifikační úpravy časové řady.



Implementace


Postklasifikační úpravy byly provedeny v ArcGIS Pro a programováním v Python. S každou úpravou byl zároveň vyhodnocován její vliv na přesnost klasifikace.

Aplikace **majoritního filtru** (MF) měla minimální vliv na přesnost klasifikace, jak ukazuje tabulka 5 na příkladu dat z let 2001 a 2010. Počet změněných pixelů nepřekročil 6 %. Uvedené statistické údaje se prakticky neliší pro případ 4 a 8prvkového sousedství. Vzhledem k menšímu vyhlazení okrajů homogenních ploch bylo dále použito sousedství 4. Prostorové rozmístění změněných pixelů bylo rovnoměrné v celém zámjmovém území, jak ukazuje obrázek 9.

Tabulka 5. Vliv použití majoritního filtru (MF) na přesnost klasifikace a počet změněných bodů na příkladu klasifikací z let 2001 a 2010. OA – absolutní přesnost klasifikace (před sloučením tříd jehličnatého lesa a kosodřeviny). 4/8 značí sousedství přes hranu/vrchol.

	2001			2010		
	původní	MF 4	MF 8	původní	MF 4	MF 8
OA	0,656	0,655	0,647	0,680	0,676	0,670
Počet změněných pixelů	-	4782	5874	-	4678	5888
% změn z celkového počtu pixelů	-	5,4	5,7	-	5,4	5,7

Obrázek 9. Prostorové rozložení změn pixelů v roce 2001 (MF 4) a v roce 2010 (MF 8).



Aplikace minimální mapovací jednotky (MMJ) 1 x 2 pixely byla realizována následujícími procesy v ArcGIS Pro:

- identifikace spojených regionů (RegionGroup),
- identifikace izolovaných pixelů, resp. ploch menších než MMU (ExtractByAttributes),
- nahrazení hodnot izolovaných pixelů (Nibble).

Vedle přesnosti klasifikace a počtu změn pixelů byl jako další ukazatel vlivu provedené filtrace vypočten počet změn tříd každého pixelu v časové řadě (V). Z tabulky 6 vyplývá, že zatímco vliv filtrace na přesnost klasifikace byl minimální, počet pixelů s neměnnou třídou krajinného pokryvu (V = 1) či jen jednou změnou (V = 2) vzrostl. Mapový výstup v příloze I ukazuje prostorové rozložení počtu tříd v jednotlivých pixelech před a po filtraci kombinace MF4 a MMJ.

Tabulka 6. Vliv použití majoritního filtru (MF) a minimální mapovací jednotky (MMJ) na přesnost klasifikace 2001 a 2010 a počet změn bodů v celé časové řadě po aplikaci filtrace. AO – absolutní přesnost klasifikace (po sloučení tříd jehličnatého lesa a kosodřeviny). 4/8 značí sousedství přes hranu/vrchol.

	2001				2010			
	původní	MF 4	MMJ	MF4 + MMJ	původní	MF 4	MMJ	MF4 + MMJ
OA	0,699	0,694	0,700	0,697	0,722	0,713	0,719	0,710

Výsledek analýzy časové řady				
Počet změn	původní	MF 4	MMU	MF4 + MMU
V = 1	18 %	21 %	19 %	21 %
V = 2	24 %	26 %	26 %	28 %
Max V	8	7	7	7
Mean V	2,8	2,6	2,7	2,6
σ_v	1,2	1,2	1,2	1,2

Výsledné datové vrstvy klasifikace po provedených úpravách byly podkladem pro další [analýzy](#) a pro mapy krajinného pokryvu, které lze nahlížet na webové stránce projektu TAČR SS05010124: <https://www.lucc4hydro.cz/krkonose-tacr-lc/>. Ukázka mapových výstupů je v příloze II.

Hodnocení přesnosti klasifikace

Při hodnocení přesnosti klasifikace se vychází z kontrolních/validačních bodů, jejichž zařazení do dílčích tříd by mělo ideálně vycházet z přesnějšího/podrobnějšího zdroje, než jsou data vstupující do klasifikace. Strategie rozdělení bodů v zájmovém území mohou být různé (Jensen, 2005), nejčastěji se používá stratifikované rozdělení se stanovením minimálního počtu bodů na třídu. Počet bodů se odvíjí od požadovaného intervalu spolehlivosti dle Foody (2009).

Implementace

Přesnost klasifikace byla hodnocena na 1500 bodech stratifikovaně rozdělených do jednotlivých tříd, dle Foody (2009) pro oboustranný interval spolehlivosti $\alpha = 5\%$ a $h=0,025$. Třída klasifikace byla validačním bodům přidělena na základě interpretace ortofot (dostupných přes WMS KRMAP a ČÚZK). V roce 2022 bylo 94 z těchto bodů, zejména tříd přechodová stadia lesa, listnatý a smíšený les, ověřeno v terénu. Vzhledem k počtu validačních bodů byla validace provedena jen v 5 časových horizontech v případě dat Landsat, jak ukazuje Tabulka 7. Klasifikace z dat Sentinel-2 byla provedena jen zkušebně v letech 2018 a 2022. Z tabulky vyplývá, že celková přesnost klasifikace z dat Landsat dosahuje 70 až 80 %. Z vegetačních tříd F1 skóre nabývá nejvyšších hodnot pro louky a pastviny, jehličnatý les a kosodřevinu. Data Sentinel-2 díky vyššímu prostorovému a spektrálnímu rozlišení umožňují docílit vyšší přesnost klasifikace, a to až o 10 %.

Tabulka 7. Přesnost klasifikace pro 1500 validačních bodů získaných interpretací ortofot. Třídy zástavba a vodní plochy nevznikly na základě klasifikace a nebyly tudíž hodnoceny. Jako míry přesnosti jsou uvedeny celková přesnost (AO) a F1-skóre (harmonický průměr uživatelské a zpracovatelské přesnosti). Pro data Sentinel je pro zajímavost přesnost dílčích tříd uvedena před sloučením podtříd jehličnatého lesa a kosodřeviny.

	Landsat 8			Landsat 5	
	2022	2018	2016	2010	2001
	F1-skóre				
Louky, pastviny	0,91	0,83	0,89	0,86	0,75
Listnatý les	0,53	0,56	0,73	0,60	0,56
Jehličnatý les	0,89	0,88	0,89	0,80	0,81
Jehličnatý les odumřelý	0,75	0,56	0,71	-	-
Smíšený les	0,57	0,53	0,61	0,42	0,43
Přechodová stadia lesa a křoviny	0,77	0,75	0,76	0,64	0,65
Holiny, oblasti s nízkou vegetací	0,78	0,55	0,71	0,39	0,42
Kosodřevina	0,91	0,8	0,82	0,82	0,72
Rašeliniště	0,98	0,93	0,85	0,68	0,83
Skály, kamenná moře	0,84	0,82	0,79	0,91	0,77
AO	0,82	0,78	0,81	0,70	0,70

	Sentinel-2	
	2022	2018
AO	0,81	0,80
	F1-skóre	
Louky, pastviny	0,92	0,89
Listnaté lesy	0,72	0,74
Jehličnaté lesy zapojené	0,89	0,89
Jehličnaté lesy nezapojené	0,67	0,64
Jehličnaté lesy odumřelé	0,87	0,78
Smíšené lesy	0,65	0,69
Přechodová stadia lesa a křoviny	0,84	0,84
Holiny, oblasti s řídkou vegetací	0,76	0,71
Kosodřevina	0,65	0,63
Kosodřevina se smrkem/jeřábem	0,55	0,33
Rašeliniště	0,90	0,92
Skály, kamenná moře	0,90	0,92
AO po sloučení podtříd	0,86	0,86

Integrated forest z-score a index disturbance

Vedle NDVI byl pro hodnocení změn lesních porostů spočítán index označovaný jako „integrated forest z-score“ (IFZ, Huang et al., 2010) a index disturbance (DI, Healey et al., 2005).

IFZ se odvozuje z normovaných hodnot odrazivosti v červeném (R) a středních infračervených pásmech (SWIR1 a SWIR 2) dle vztahů

$$FZ_i = \frac{b_i - \bar{b}_i}{SD_i} \quad IFZ = \sqrt{\frac{\sum_{k=1}^3 FZ_k^2}{3}}$$

kde hodnoty \bar{b}_i a SD_i představují průměr a směrodatnou odchylku odrazivosti pixelů odpovídajících lesnímu porostu. Dle Huang et al. (2010) lesní porosty v časové řadě vykazují hodnoty IFZ < 3. Nárůst IFZ nad tuto prahovou hodnotu indikuje odlesnění.

Pro výpočet DI je třeba provést transformaci Tasseled cap a podobně jako u IFZ normovat hodnoty jasu (B), zeleně (G) a vlhkosti (W) pomocí průměru a směrodatné odchylky těchto hodnot v pixelech odpovídajících lesním porostům.

$$DI = B_r - (G_r + W_r),$$


Kde B_r , G_r a W_r jsou normované hodnoty komponent Tasseled cap transformace. DI vychází z předpokladu, že nedávno vykácený nebo degradující les vykazuje vysoký jas a nízké hodnoty zeleně a vlhkosti ve vztahu ke zdravému nebo obnovujícímu se lesu. Z trendu DI (tj. hodnota směrnice regresní přímky) v daném časovém úseku lze sledovat vývoj celkového stavu lesního porostu.

Implementace

IFZ a DI byly vypočteny pro všechny časové horizonty pomocí skriptu pro MATLAB. Pro normalizaci byly využity hodnoty pixelů spadajících do tříd nepoškozeného vzrostlého lesa (jehličnatý, listnatý, smíšený) a kosodřeviny (tj. třídy 310, 320, 330, 400). Obrázek 11 ukazuje průměrné hodnoty IFZ pro jednotlivé třídy krajinného povrchu v dílčích letech. Příslušnost ke třídě krajinného pokryvu vychází z klasifikace popsané výše. Z grafu je patrné rozdělení tříd odpovídajících lesní vegetaci včetně přechodových stadií a kosodřeviny s IFZ < 3 a tříd odpovídajících loukám, holinám, skalám a zástavbě s IFZ > 3. Specifickou kategorií jsou rašeliniště, která se pohybují mezi oběma skupinami krajinného pokryvu. Dle Huang et

al. (2010) by vodní plochy a v našem případě i rašeliniště měly být z analýzy IFZ odmaskovány, protože mohou mylně indikovat lesní porosty (nejtmavší pixely v obrazu).

Obrázek 11. Časová řada průměrných hodnot IFZ v zájmovém území dle kategorií krajinného pokryvu.




Analýzy časové řady

Získané časové řady klasifikace a spektrálních indexů jsou předmětem analýz vedoucích k vyhodnocení změn lesních porostů v zájmovém území. Výsledky analýz lze prezentovat mapovými výstupy a statistickými ukazateli, jejichž příklady následují.

Příklady analýzy časové řady výstupů klasifikace

Na základě časové řady klasifikace lze identifikovat stabilní plochy v zájmovém území, jak ukazuje mapa v příloze III. Graf na obrázku 12 vyjadřuje plochu klasifikovaných kategorií ve sledovaném období. Mapa v příloze IV vedle stabilních ploch lesa indikuje, kde v průběhu sledovaného období došlo k přeměně holiny nebo přechodového stádia lesa na vzrostlý les (smíšený, listnatý nebo jehličnatý). Mapa v příloze V prezentuje počáteční a koncový časový horizont z hlediska nezměněných ploch a tříd krajinného pokryvu v místech mimo nezměněné plochy.

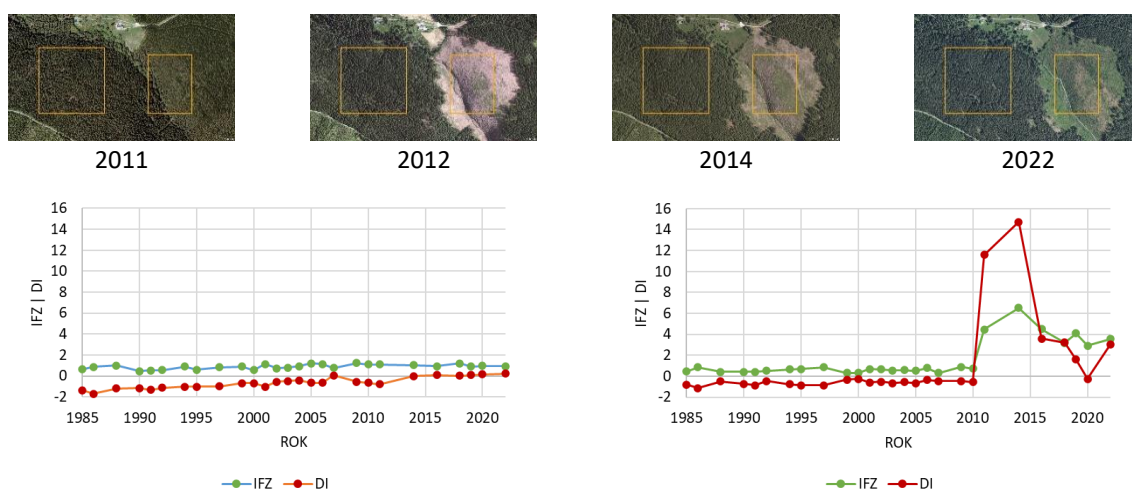
Obrázek 12. Rozloha klasifikovaných tříd v zájmovém území v průběhu sledovaného časového období.



Příklady analýzy časové řady vybraných indexů

Analýza časových řad odvozených indexů – NDVI, IFZ, DI umožňuje detekovat termín degradace lesního porostu (polom, zničení lesa škůdcem, vykácení) či naopak jeho obnovy (obrázek 13). Z vypočteného trendu DI lze lokalizovat území se zlepšujícím/zhoršujícím se stavem lesního porostu ve zvoleném časovém období, jak ukazuje mapa v příloze VI. K určení termínu největší změny lesního porostu lze využít algoritmus LandTrendr (Kennedy et al., 2010) – na mapě v příloze VII byl aplikován na index IFZ.

Obrázek 13. Grafy IFZ a DI v oblasti Chaloupky (50°41'37.61"N, 15°43'19.53"E), kde došlo v roce 2012 k odlesnění. Graf vlevo ukazuje průměrné hodnoty IFZ a DI trvale zalesněné plochy, graf vpravo plochy odlesněné. V časové řadě chybí data z let 2012 a 2013.



Závěr

Navržený metodický postup využití družicových dat DPZ pro monitoring změny krajinného pokryvu s důrazem na hodnocení změn lesních porostů byl úspěšně ověřen na datové sadě Landsat z období 1985–2022. Jako vedlejší produkt vznikl skript pro předzpracování dat v prostředí Google Earth Engine, který může být využíván a popř. dále rozvíjen. Byla navržena sada postklasifikačních pravidel. Vytvořená časová řada klasifikace krajinného pokryvu v zájmových povodí vykazuje v kontrolních časových řezech konzistentní přesnost mezi 70–80 %. Bude využita jako vstup pro simulaci vlivu změn krajinného pokryvu na vývoj hydrologických charakteristik v modelu SWAT.

Možností analýzy časových řad výsledků klasifikace a vybraných vegetačních indexů (NDVI, IFZ, DI) pro hodnocení vývoje lesních porostů existuje celá řada, jejich výběr závisí na konkrétních požadavcích uživatele. V závěrečné sekci této metodiky jsou zmíněny jen některé z nich.

Navržená metodika je přenositelná na jiné typy družicových dat podobného spektrálního a prostorového rozlišení (zejména Sentinel-2), popř. harmonizovaných produktů (např. HLS)

Použitý postup řízené klasifikace vyžadující manuální sběr trénovacích a validačních dat je primárně určen pro hodnocení stavu relativně homogenní lesní vegetace a v ploše odpovídající sledovaným povodím, tj. do 100 km². Naopak indikátory stavu lesní vegetace založené na spektrálních charakteristikách jsou snadno implementovatelné pro větší území i více heterogenní porosty. Manuální práci lze do jisté míry nahradit přenosem klasifikátoru z jiných let, což může mít vliv na snížení přesnosti klasifikace v případě nedostatečného radiometrického vyrovnání snímků mezi dvěma a více časovými horizonty, jak bylo v implementační části metodiky ukázáno.

Požadavek existence ortofot pro sběr trénovacích dat a cíl pořídit bezoblačnou mozaiku s co nejmenším počtem scén z vedlejších let způsobil, že vytvořená časová řada není zcela pravidelná, což má své důsledky v možnosti včasné detekce některých změn, resp. jejich rozpoznání vůbec. Nepravidelnost časové řady ovlivňuje i výsledek vyhlazení klasifikace, popř. indexů mezi časovými horizonty. Tento nedostatek je dán kvalitou snímků, resp. vysokým stupněm oblačnosti v konkrétním zájmovém území, a dostupností podpůrných dat. Vlastní metodický postup je na použitém modelovém příkladě nezávislý.

Literatura a zdroje

Baig, M. H. A., Zhang, L., Shuai, T., Tong, Q. (2014). Derivation of a tasseled cap transformation based on Landsat 8 at-satellite reflectance. *Remote Sensing Letters*, 5(5), 423-431.

Copernicus (2023): <https://www.copernicus.eu/en>. [19-12-2023]

Crist, E. P., Cicone, R. C. (1984). A physically-based transformation of Thematic Mapper data---The TM Tasseled Cap. *IEEE Transactions on Geoscience and Remote sensing*, (3), 256-263.

ČÚZK (2023): <https://geoportal.cuzk.cz/>. [19-12-2023]

Foody, G. M. (2009): Sample size determination for image classification accuracy assessment and comparison *Int. J. Remote Sens.*, 30, 5273–5291.

GEE_vizualizace (2023): Aplikace pro zobrazení bezoblačných scén Landsat 1985–2022. <https://dvorakjakub.users.earthengine.app/view/kompozitykrkonose>. [19-12-2023]

Jensen, J.R. (2005): *Introductory Digital Image Processing: A Remote Sensing Perspective*, 3rd ed., Pearson Education, Upper Saddle River.

KRNAP (2023): <https://www.krnep.cz/mapovy-server-a-gis/>. [19-12-2023]

Kennedy, R. E., Yang, Z., Cohen, W. B. (2010). Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr—Temporal segmentation algorithms. *Remote Sensing of Environment*, 114(12), 2897-2910.

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, 113645

Landsat (2023): <https://www.usgs.gov/landsat-missions/landsat-satellite-missions>. [19-12-2023]

Landsat QA (2023): <https://www.usgs.gov/landsat-missions/landsat-collection-2-quality-assessment-bands>. [19-12-2023]

Sentinel-2 Level 2A (2023): <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-2-msi/level-2a/algorithm-overview>. [19-12-2023]

Shi, T., Xu, H. (2019). Derivation of tasseled cap transformation coefficients for Sentinel-2 MSI at-sensor reflectance data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(10), 4038-4048.

ÚHÚL (2023): <https://www.uhul.cz/mapy-a-data/webove-mapove-sluzby/>. [19-12-2023]

USGS (2023): <https://earthexplorer.usgs.gov/>. [19-12-2023]

Přílohy


Příloha I: Vliv monotemporální filtrace na počet změn klasifikační třídy

VÝSKYT TŘÍD V PIXELU V RÁMCI ČASOVÉ ŘADY


1985–2022, povodí horní Úpy a horní Čisté

zdroj dat: Landsat 5,7,8

před
postklasifikačními úpravami





počet tříd



2 km

po
majoritním filtrování a stanovení MMJ




Příloha II: Mapy krajinného pokryvu 2010 a 2018

LAND COVER 2010

povodí horní Úpy a horní Čisté

zdroj dat: Landsat 5



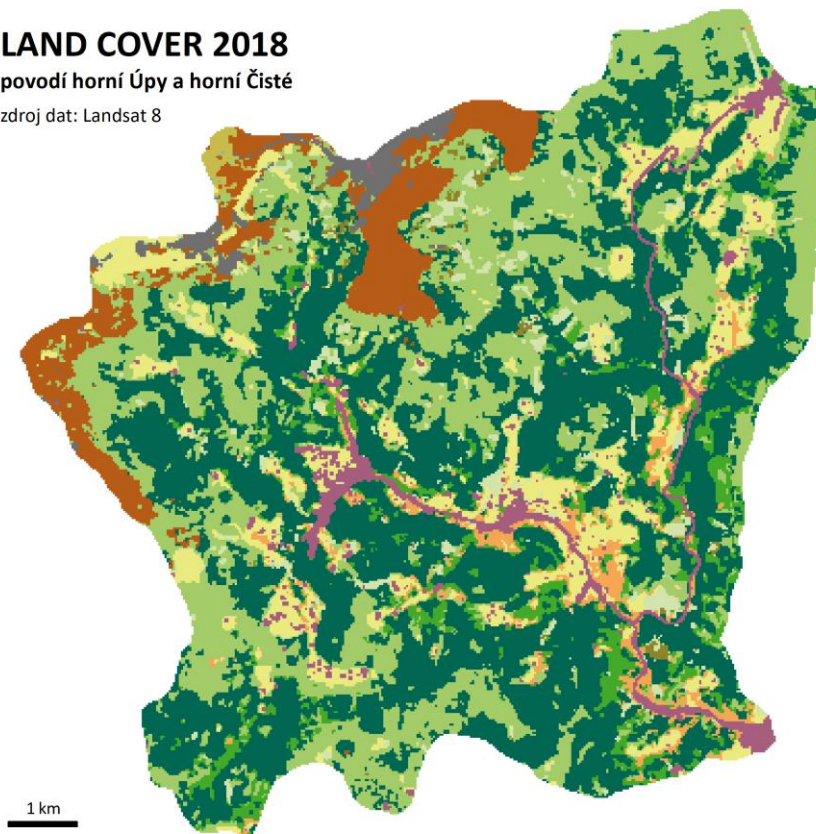
Vytvořeno v rámci projektu TAČR SS05010124:
Hodnocení vlivu změn krajinného pokryvu na
lokální hydrologii a klima v Krkonošském
národním parku s využitím dálkového průzkumu
Země a hydrologického modelování

- Louky, pastviny
- Listnatý les
- Jehličnatý les
- Smíšený les
- Přechodová stadia lesa a křoviny
- Holiny, oblasti s nízkou vegetací
- Kosodřevina
- Rašeliniště
- Skály, kamenná moře
- Vodní plochy a toky
- Zástavba a komunikace

LAND COVER 2018

povodí horní Úpy a horní Čisté

zdroj dat: Landsat 8

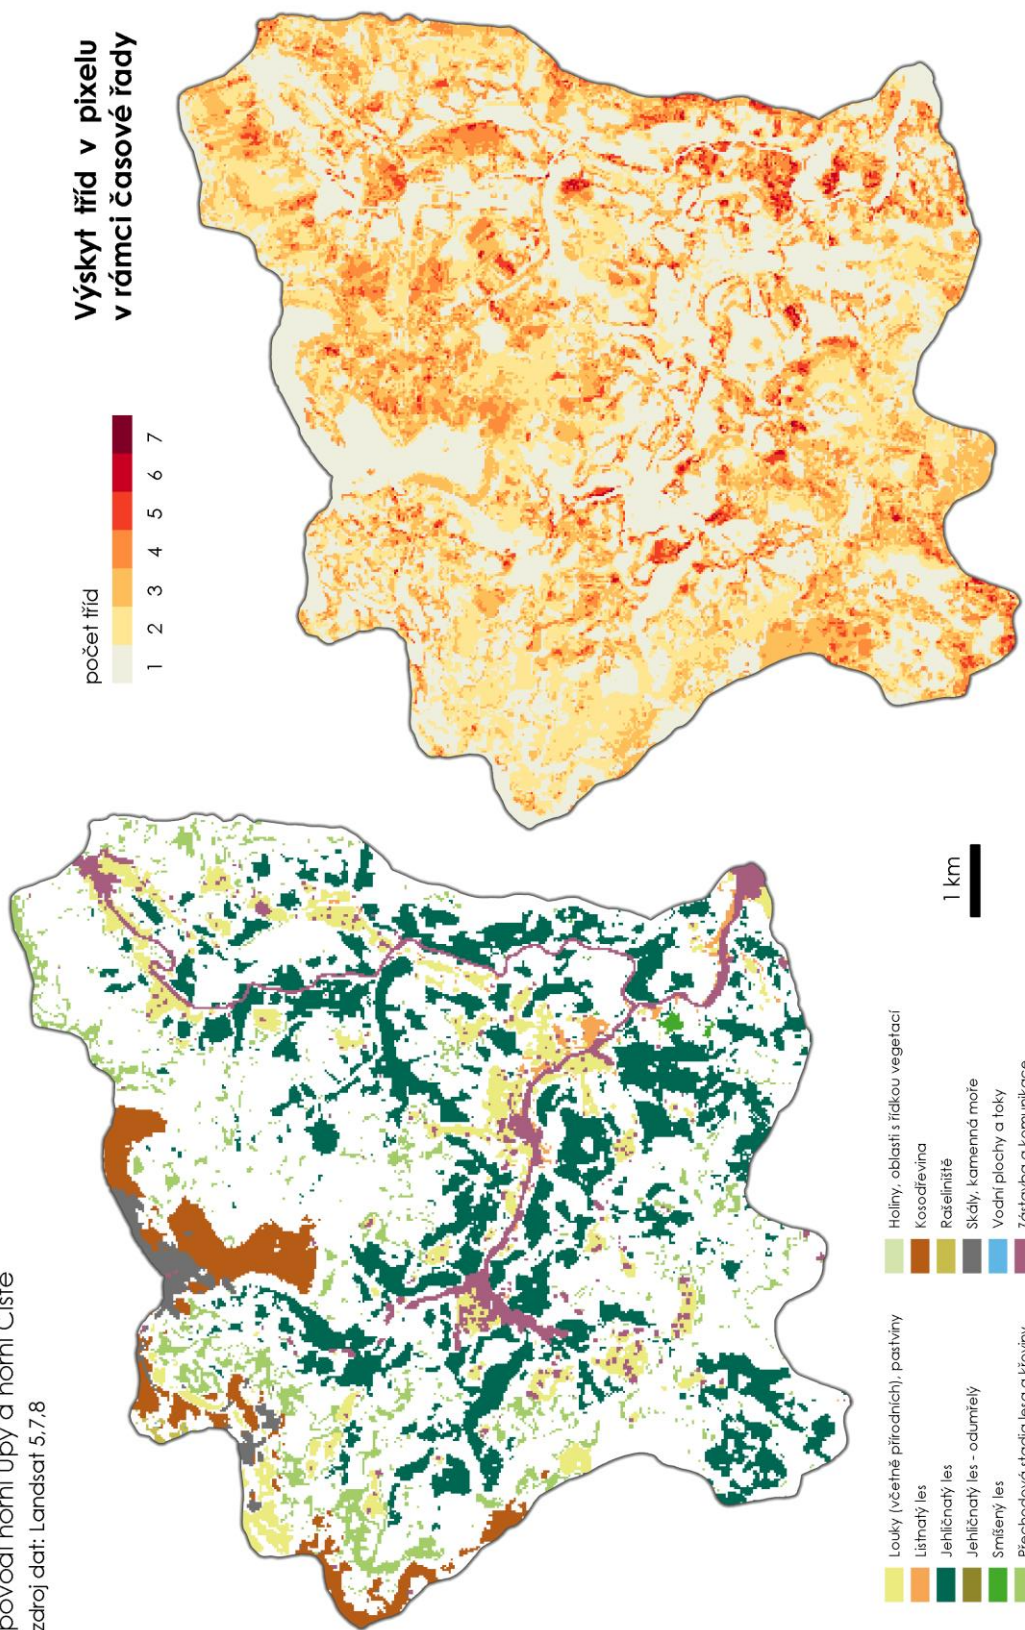


Vytvořeno v rámci projektu TAČR SS05010124:
Hodnocení vlivu změn krajinného pokryvu na
lokální hydrologii a klima v Krkonošském
národním parku s využitím dálkového průzkumu
Země a hydrologického modelování

- Louky, pastviny
- Listnatý les
- Jehličnatý les zapojený
- Jehličnatý les poškozený/odumřelý
- Smíšený les
- Přechodová stadia lesa a křoviny
- Holiny, oblasti s nízkou vegetací
- Kosodřevina
- Rašeliniště
- Skály, kamenná moře
- Vodní plochy a toky
- Zástavba a komunikace

STABILNÍ PLOCHY LAND COVER v letech 1985–2022

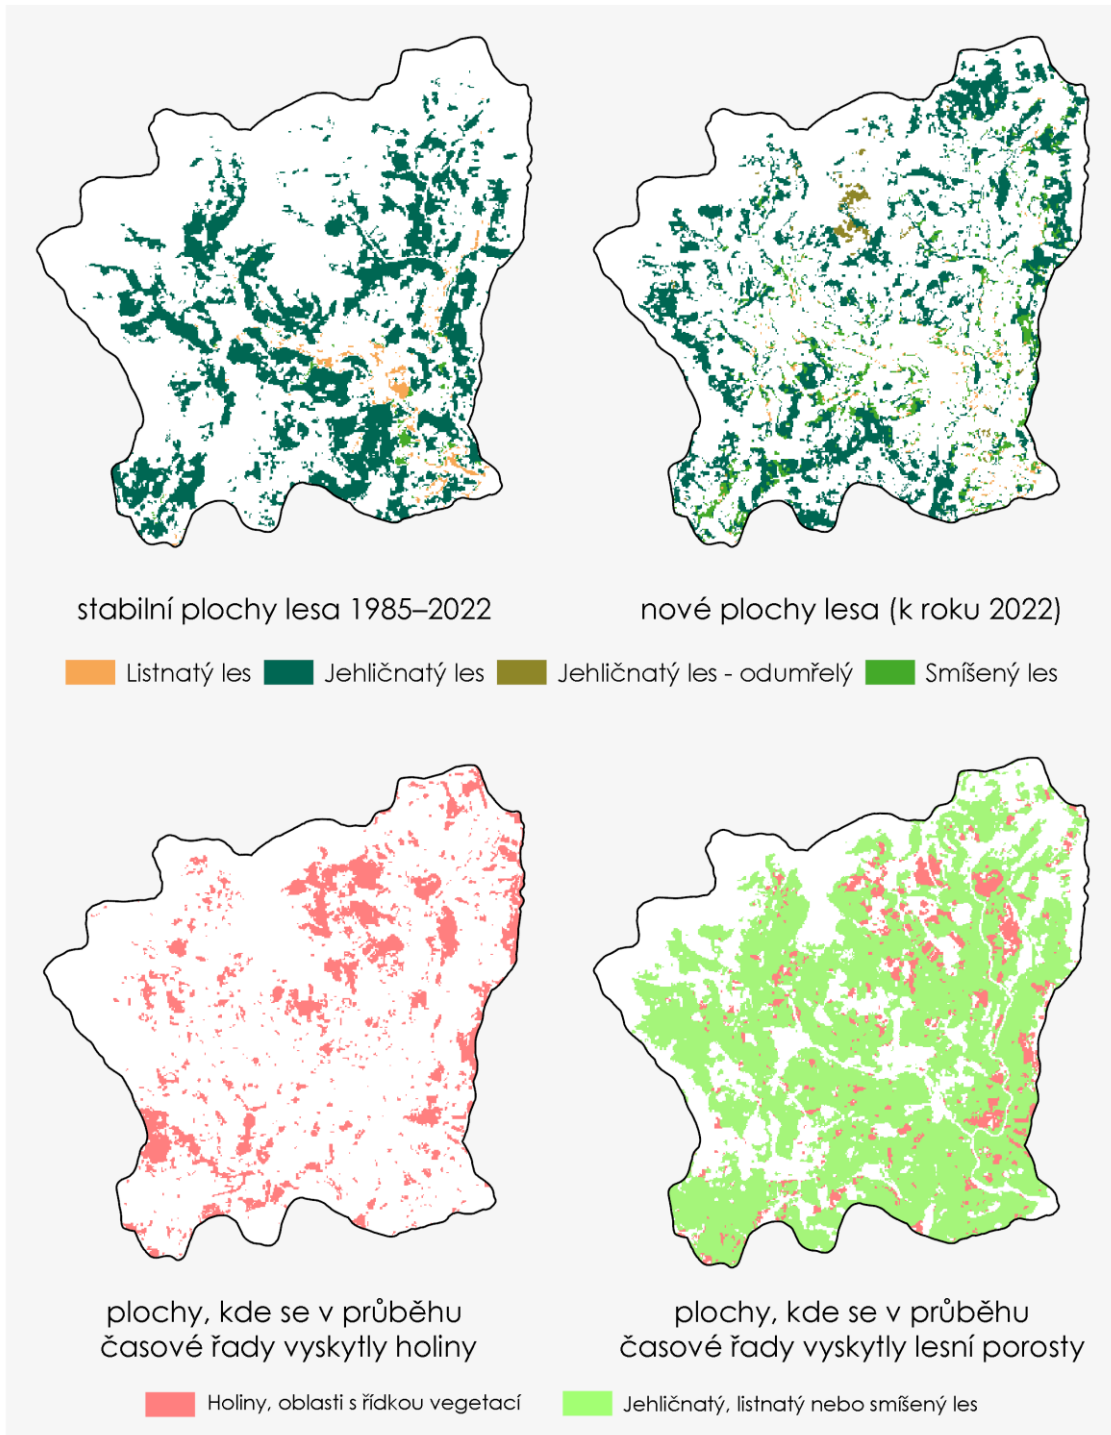
povodí horní Úpy a horní Čistě
zdroj dat: Landsat 5,7,8



ZMĚNA LESNÍCH POROSTŮ

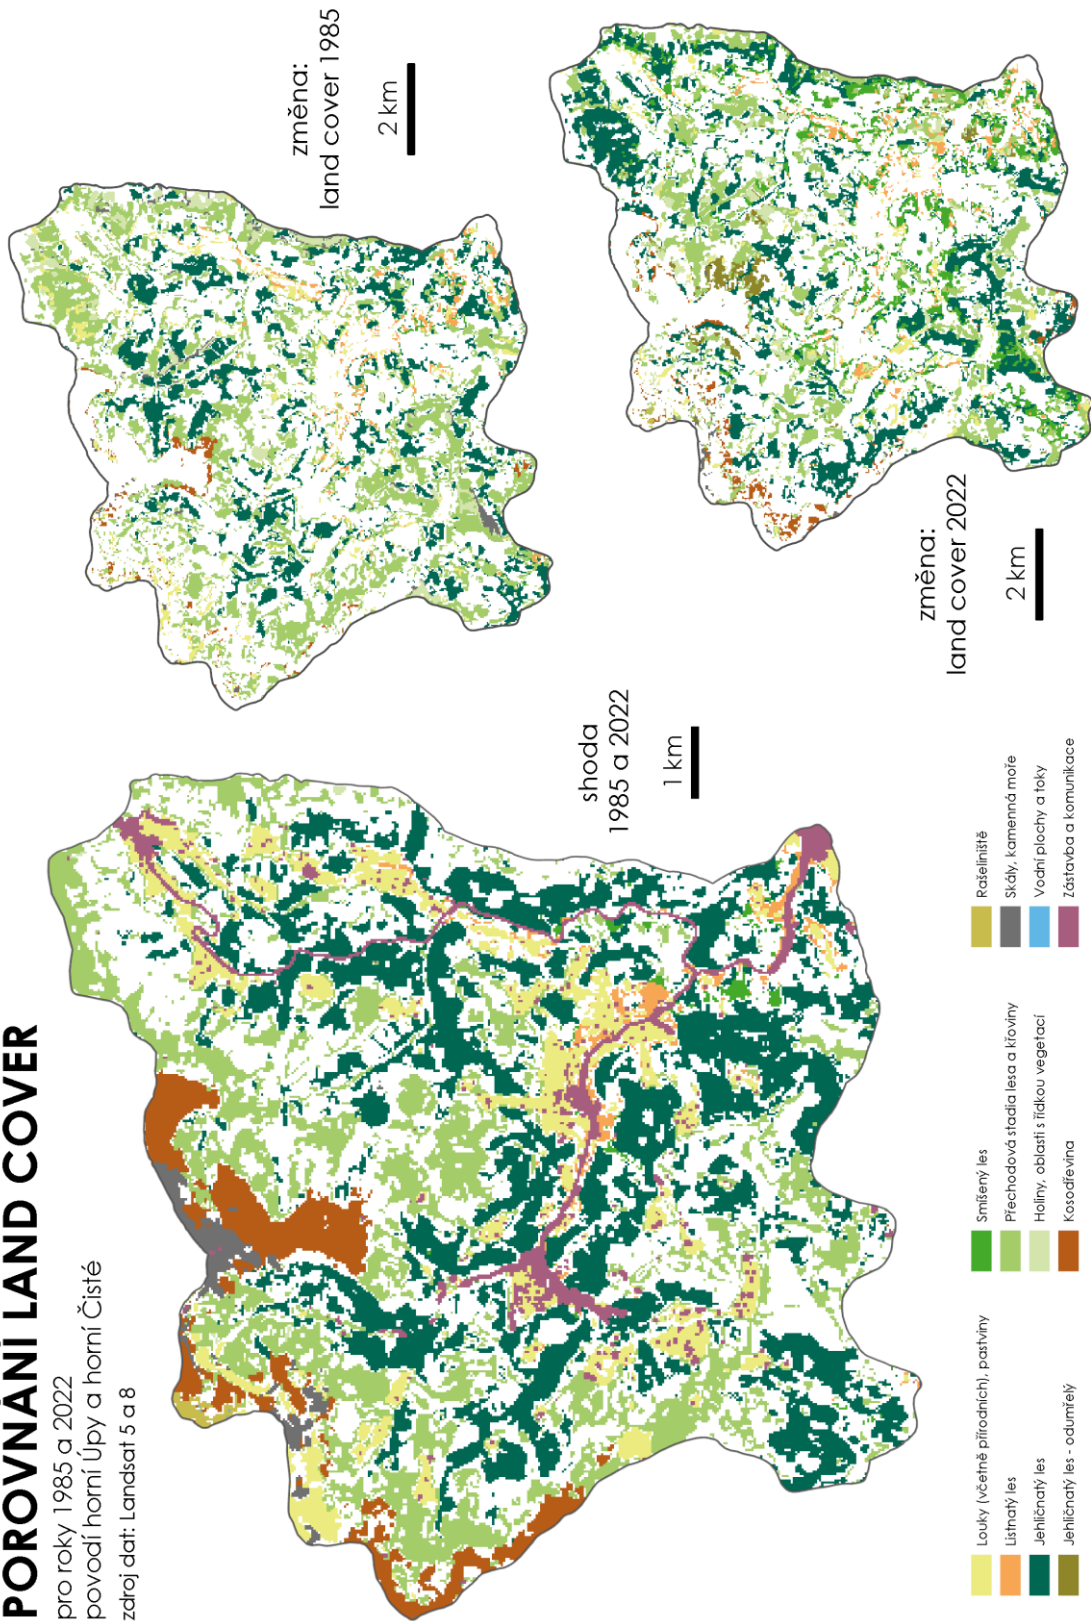
1985–2022, povodí horní Úpy a horní Čisté

zdroj dat: Landsat 5,7,8




POROVNÁNÍ LAND COVER

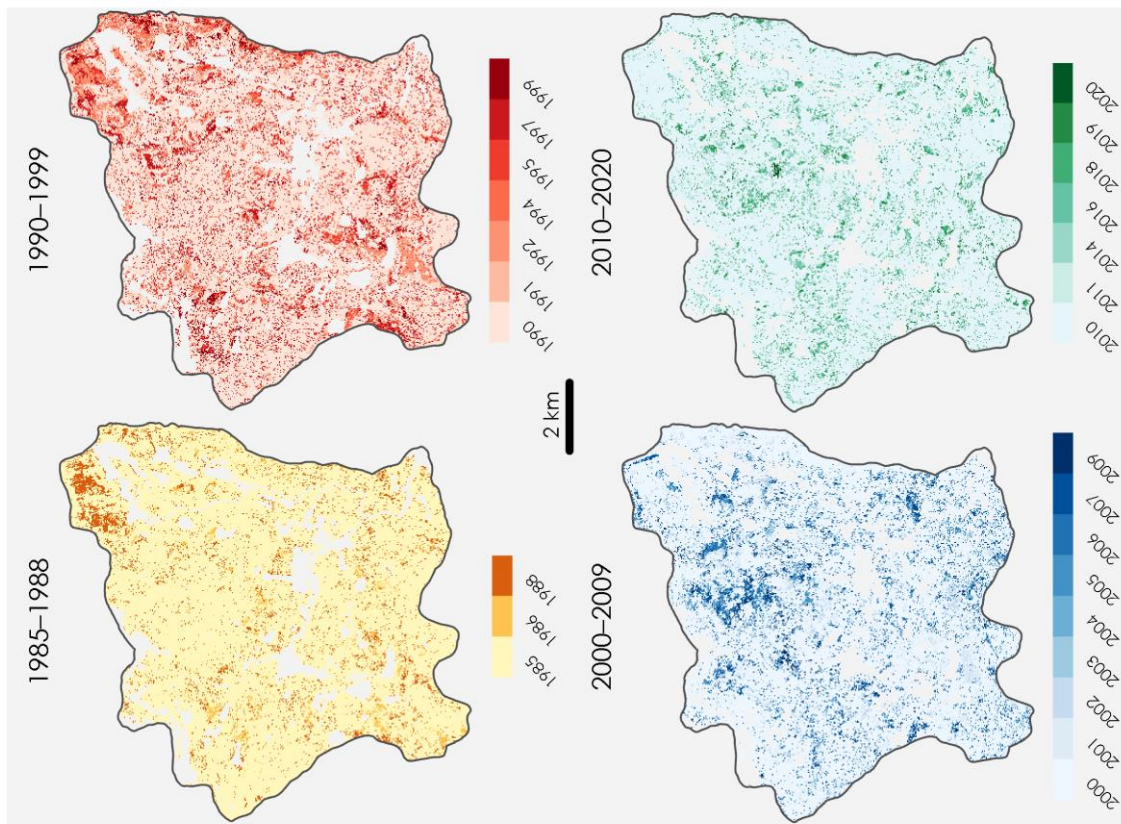
pro roky 1985 a 2022
 povodí horní Úpy a horní Čistě
 zdroj dat: Landsat 5 a 8



TREND INDEXU DISTURBANCE v letech 2002–2022
povodí horní Úpy a horní Čistě
zdroj dat: Landsat 5,7,8




Příloha VII: Nejvýznamnější změna IFZ mezi roky 1985–2022



INTEGRATED FOREST Z-SCORE (IFZ)

termíny nejvýraznější změny lesního porostu dle indexu IFZ
1985–2022, povodí horní Úpy a horní Čistě
zdroj dat: Landsat 5,7,8



Období nejvýraznější změny

1985–1989
1990–1999
2000–2009
2010–2022