



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 hodnocení zdravotního stavu lesních porostů s využitím
letecké obrazové spektroskopie a krátkodobých trendů spektrálních
indikátorů
(V22)**

Autorský kolektiv:

Vojtěch Bárta, Petr Lukeš a Lucie Homolová / Ústav výzkumu globální změny AV ČR
Lucie Červená, Zuzana Lhotáková a Lucie Kupková / Přírodovědecká fakulta Univerzity Karlovy

Ústav výzkumu globální změny AV ČR, prosinec 2024

Obsah

1. Úvod	2
1.1. Stav lesních porostů v ČR	2
1.2. Zdravotní stav lesů pohledem DPZ.....	2
1.3. Zdroje dat DPZ pro monitorování stavu lesa	3
Letecká a UAV data	3
Satelitní multispektrální data.....	4
2. Cíle dílčí metodiky	5
3. Vstupní data	5
3.1. Pozemní šetření.....	5
3.2. Letecká obrazová spektroskopie	7
3.3. Satelitní data Sentinel-2	9
4. Metodický postup	11
4.1. Spektrální indikátory odvozené z letecké obrazové spektroskopie	11
Empirické odhady biochemických indikátorů	11
Hyperspektrální vegetační indexy.....	12
4.2. Krátkodobé trendy spektrálních indikátorů ze satelitních dat Sentinel-2.....	13
4.3. Identifikace postižených a výrazně ohrožených porostů	15
5. Výsledky	16
5.1. Spektrální indikátory odvozené z letecké obrazové spektroskopie	16
5.2. Krátkodobé trendy spektrálních indikátorů ze satelitních dat Sentinel-2.....	18
5.3. Identifikace poškozených porostů a porostů náchylných k dalšímu poškození.....	20
6. Závěr	22
7. Seznam zkratek	24
8. Citovaná literatura	25

1. Úvod

1.1. Stav lesních porostů v ČR

Rozloha lesů v České republice činí zhruba 33 % území, což je obdobný podíl plochy jako v celé Evropě, v posledních letech jejich plocha setrvale roste. Z hlediska funkcí se rozložení do kategorií lesů, tj. lesy hospodářské (cca 74 %), ochranné (2 %) a zvláštního určení (24 %), se za posledních 20 let výrazně nezměnilo (MZe, 2023). Nejvýznamnější změnou v lesních porostech poslední dekády je však masivní úbytek produkčních jehličnatých, zejména smrkových porostů, které byly v posledních dvaceti letech značně stresovány epizodami sucha, následovanou kalamitní invazí lýkožrouta smrkového (Brázdil et al., 2022; Hlásny et al., 2021). Tato situace vedla k masivní těžbě v zasažených oblastech, které v důsledku kůrovcové kalamity dosahovaly maxima téměř 35 tis. m³ v roce v 2020 (MZe, 2023).

V zvláště chráněných územích (ZCHÚ) jako jsou národní parky a chráněné krajinné oblasti jsou přírodě blízké lesní ekosystémy domínatným typem krajinného pokryvu. V národních parcích ČR pokrývají lesy více jak 80% území (MZe, 2023). V KRNAP je to téměř 88% s dominantním zastoupením smrku ztepilého.

1.2. Zdravotní stav lesů pohledem DPZ

Momentálně monitoring zdravotního stavu lesa z DPZ (dálkového průzkumu Země) používá ÚHÚL (Ústav pro hospodářskou úpravu lesů) na základě metody založené na volně dostupných satelitních datech Sentinel-2 (Lukeš et al., 2018). Metoda hodnotí změny indexu listové plochy (potažmo míry defoliace) v prostorovém rozlišení 20 m mezi jednotlivými roky. Jelikož hodnocení zdravotního stavu pomocí DPZ není dle MZe (2023) natolik spolehlivé, i nadále se používá opakovaných pozemních šetření v rámci monitoringu ICP Forests (Vejpustková, 2019) a národní inventarizace lesů (<https://nil.uhul.cz/>). Data pozemního šetření jsou pak důležitým zdrojem dat pro vývoj a validaci metod založených na DPZ. ÚHÚL dále vyhodnocuje komerční satelitní snímky Planet (Planet Labs Inc.) s prostorovým rozlišením 5 m, které ve vyšším prostorovém rozlišení mapují rozsah a průběh kůrovcové kalamity, tzn.. plochy těžeb a souší v převážně jehličnatých porostech v každém roce (viz <https://www.kurovcovamapa.cz>).

Na Slovensku se k hodnocení trendů zdravotního stavu lesů z podkladů DPZ věnuje Národní lesnické centrum ve Zvoleně. Využívají k tomu interpretaci satelitních dat Landsat, resp. Sentinel-2 pro klasifikaci porostů do 4 tříd - bez poškození, slabě poškozené porosty, středně poškozené porosty a silně poškozené porosty. Mapová aplikace umožňuje vizuální porovnání stavu lesních porostů ve dvou uživateli zvolených letech (Bucha et al., 2014).

Metody založené na datech dálkového průzkumu Země tak umožňují sledování rozsáhlých území v relativně pravidelném časovém kroku. Jejich plošný rozsah je jejich hlavní výhodou oproti metodám pozemního šetření, které nemohou v jednom čase pokrýt rozsáhlá území. Paleta dostupných dat DPZ se neustále zvětšuje, stejně tak jako jejich cenová dostupnost pro řadové uživatele. Každý typ dat má

své výhody a nevýhody a umožňuje sledovat různé charakteristiky lesních porostů v různém prostorovém, spektrálním a časovém rozlišení, jak je podrobněji rozepsáno v následující kapitole.

1.3. Zdroje dat DPZ pro monitorování stavu lesa

Letecká a UAV data

Letecká a UAV (z angl. Unmanned Aerial Vehicles neboli drony) data představují dvě klíčové technologie pro sběr velmi detailních dat o lesních porostech. Oba typy nosičů umožňují sběr dat s velmi vysokým prostorovým rozlišením (v řádu centimetrů až metrů), což je důležité pro přesné monitorování menších oblastí, kde je potřeba detailní analýza až třeba na úroveň jednotlivých stromů. Oba typy nosičů umožňují osazení různými senzory, jako jsou optické kamery, multispektrální a hyperspektrální senzory, Lidary (ze angl. zkratky Light Detection And Ranging) nebo termální kamery, které umožňují sbírat různé typy dat o vegetaci, terénu, teplotních změnách a dalších vlastnostech povrchů. Letecké nosiče jsou díky své velikosti vhodnější pro kombinaci několika senzorů, než drony. Příkladem takového leteckého nosiče je výzkumná letecká laboratoř FLIS (z angl. Flying Laboratory of Imaging Systems), kterou provozuje Ústav výzkumu globální změny AV ČR, a která umožňuje souběžné pořízení hyperspektrálních, lidarových a termálních dat (více na <https://olc.czechglobe.cz/flis/> a Hanuš et al. (2023)). Letecká data oproti dronům umožňují snímkovat větší území a jsou tak využívána pro mapování rozsáhlých oblastí v rámci celostátních nebo regionálních projektů. Např. celostátní letecké ortofoto snímkování (klasické RGB snímky), které zajišťuje ČÚZK Ta probíhá ve dvouletých intervalech, každý rok se pořizují snímky jen pro jednu polovinu území republiky. Pro velkoplošné chráněné krajinné oblasti jako je KRNAP jsou letecká data jediným možným zdrojem pro detailní mapování, jelikož takto rozsáhlé území není možné pokrýt daty dronovými. Naopak jednou z hlavních výhod UAV je jejich operabilní a cílené nasazení na konkrétní lokalitu téměř kdykoliv, když je to potřeba. Jejich nevýhodou je omezený dosah, nižší nosnost a kapacita baterií, praktické využití je kromě technických omezení určeno i platnou legislativou (např. omezení provozu UAV ve zvláště chráněných územích).

Box 1. Výhody a nevýhody leteckých a UAV dat

Výhody (+)	Nevýhody (-)
(+) vysoké prostorové rozlišení (+) u leteckých dat možnost zmapovat větší území (+) možnost kombinace různých senzorů a typů dat (+) možnost flexibilní akvizice dle požadavků uživatele	(-) u UAV dat je omezen prostorový dosah na lokální zájmová území (-) závislost na dobrém počasí (-) omezení provozu UAV ve ZCHÚ (-) náročnější předzpracování dat před vlastní analýzou (radiometrické, geometrické a atmosférické korekce) (-) u leteckých dat to mohou být vyšší pořizovací náklady a náklady na zpracování

Satelitní multispektrální data

S rozvojem digitálních technologií v 70.tých letech minulého století se pojí první civilní systém pro pozorování Země - série satelitů Landsat provozovaných NASA. Plně digitální multispektrální snímače na satelitech Landsat jsou de-facto dodnes standardem pro environmentální data DPZ (Cohen and Goward, 2004; Hansen and Loveland, 2012; Masek et al., 2020). Všechny satelity Landsat mají podobné specifika - snímají systematicky zemský povrch cca jednou za 16 dní v prostorovém rozlišení 30 - 60 m na pixel v několika spektrálních kanálech ve viditelném, blízkém infračerveném a středním infračerveném pásmu vlnových délek. Veškerá data jsou uchovávána v archivech a dostupná ve formě časových řad. Vzhledem k poměrně širokému záběru (185 km) jsou data vhodná pro sledování velkých území a k mapování v měřítku celých kontinentů. Multispektrální satelitní senzory "landsatového typu" výrazně rozšířilo vypuštění satelitního systému Sentinel-2 Evropské vesmírné agentury ESA (Drusch et al. 2012). Ten nabízí podobné parametry jako systém Landsat (prostorové rozlišení 10 a 20 m), ale jeho výraznou předností je kratší čas opětovného snímání jednoho místa a to s frekvencí 5 dní (srovnej se 16 dny u Landsatu) a přítomnost několika speciálních pásem v oblasti red-edge pro získání indikátorů spojených se zdravotním stavem vegetace (Delegido et al., 2011). Díky podobnosti obou systémů vzniká harmonizovaný Landsat a Sentinel-2 produkt (HLS), který kombinuje data z obou systémů do jedné produktové řady a výrazně tak zvyšuje časové rozlišení (Claverie et al., 2018)). Tyto hustší časové řady jsou pak vhodné ke sledování sezónního průběhu stavu vegetace (Švik et al., 2023).

V rámci lesů ČR a střední Evropy byla multispektrální satelitní data Landsat, Sentinel-2 a potažmo HLS využita a testována v následujících studiích. Pro detekci lesů postižených kůrovcem analyzoval Bárta et al. (2021) sezónní průběh spektrálních indexů ze Sentinelu-2, Hais et al. (2016) pak víceleté spektrální trajektorie indexů z Landsat snímků, König et al. (2023) pak kombinoval snímky z Landsatu, Sentinel-2 a radarová data ze Sentinel-1, a Abdullah et al. (2019) testoval spektrální indexy jak ze Sentinelu-2 tak z Landsatu 8. Časové řady kombinující Sentinel-1 a Sentinel-2 využívají např. ke klasifikaci 11 druhů dřevin v Německu (Blickensdörfer et al., 2024). Hojně se data používají k detekci disturbancí lesa (Hais et al., 2009; Hansen et al., 2013; Kupková et al., 2018; Senf et al., 2017). Lukeš et al. (Lukeš et al., 2018) používá data Sentinel-2 pro odhad indexu listové plochy lesních porostů a tuto metodiku v současné době používá ÚHUL pro hodnocení zdravotního stavu lesních porostů v ČR..

Samozřejmě kromě satelitů Landsat a Sentinel-2 existuje nepřeberné množství komerčních satelitů pro získání dat velmi vysokého prostorového rozlišení (např. WorldView-3 a WorldView-4 od společnosti Maxar Technologies, Pléiades od Airbusu), satelitů pro sledování globálních trendů vegetace s poměrně hrubým prostorovým rozlišením v řádu stovek metrů až kilometrů (jako např. MODIS), experimentálních satelitů jako jsou hyperspektrální mise EnMap, PRISMA, tyto prostředky jsou ovšem mimo záběr této metodiky.

Box 2. Výhody a nevýhody satelitních multispektrálních dat

Výhody (+)	Nevýhody (-)
(+) globální a konzistentní pokrytí (+) prostorové rozlišení (10 - 30 m) umožňující analýzu na úrovni porostů (+) možnost pravidelného opakovaného snímkování umožňující analýzy časových řad sledování změn v čase (+) otevřený přístup	(-) dostupnost snímků je závislá na oblačnosti (-) omezené spektrální rozlišení (-) prostorové rozlišení může být limitující pro detailní analýzy

2. Cíle dílčí metodiky

Cílem této dílčí metodiky je zhodnotit aktuální zdravotní stav lesních porostů v zájmových lokalitách pomocí hyperspektrálních leteckých dat a krátkodobých trendů odvozených ze satelitních dat a zpracovat mapy zdravotního stavu lesních porostů a stanovit porosty náchylné k rozpadu v nejbližších letech.

3. Vstupní data

3.1. Pozemní šetření

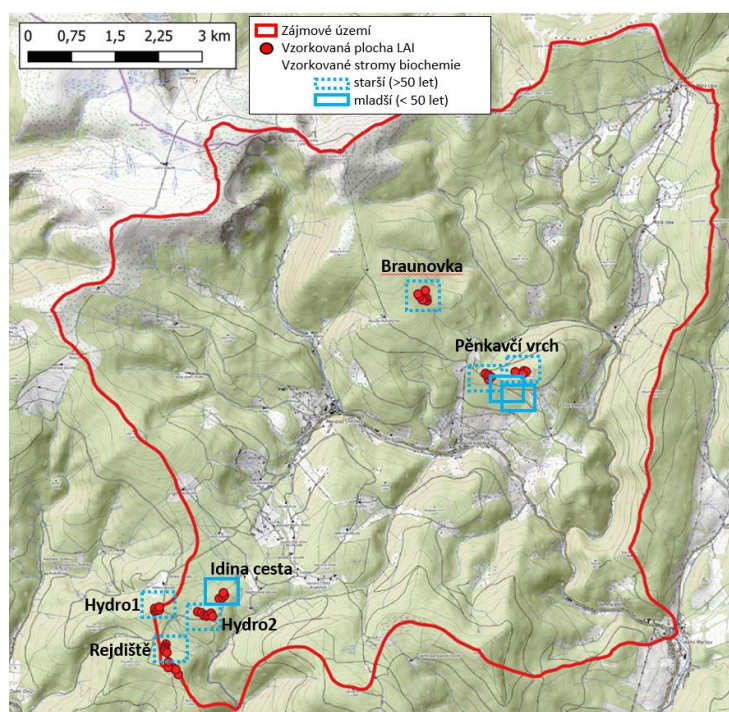
Data pozemního šetření jsou nezbytná pro kalibraci modelů založených na datech DPZ a nebo pro jejich validaci. Pro tuto metodiku byly vybrány biochemické indikátory listové biomasy, obsah fotosynteticky aktivních pigmentů (chlorofyl a+b a karotenoidy) a obsah vody v listoví. Účelem pozemních šetření je postihnout možnou variabilitu těchto indikátorů v zájmové lokalitě. Z pohledu následné statistické analýzy je nutné zvážit množství vzorků (řádově desítky), které budou sloužit ke kalibraci či validaci modelu. Zároveň však počet vzorků bude i rozumným kompromisem z pohledu časové náročnosti odběru a zpracování listových vzorků.

Pro účely této metodiky proběhla pozemní kampaň ve dnech 19. až 21. 7. 2022, kde byly na devíti lokalitách v rámci studované části povodí Horní Úpy a Horní Čisté (obrázek 1) odebrány vzorky listoví z 82 jedinců smrku ztepilého (z toho 72 stromů ve věku nad 40 let a 10 mladších jedinců pod 40 let). Vzorky jehlic byly odebrány pomocí bezeškodné stromolezecké techniky z osluněných větví z horní části korun. Jehlice prvních, druhých a čtvrtých ročníků (výhonů) byly do 24 hodin zpracovány v laboratoři PŘF UK, kde byla zjištěna jejich čerstvá hmotnost, projekční plocha jehlic. Dále byly odebrány vzorky pro spektrofotometrické stanovení obsahu fotosyntetických pigmentů. Fotosyntetické pigmenty (obsah chlorofylu a+b, dále jako Cab a celkové karotenoidy, dále jako Car)

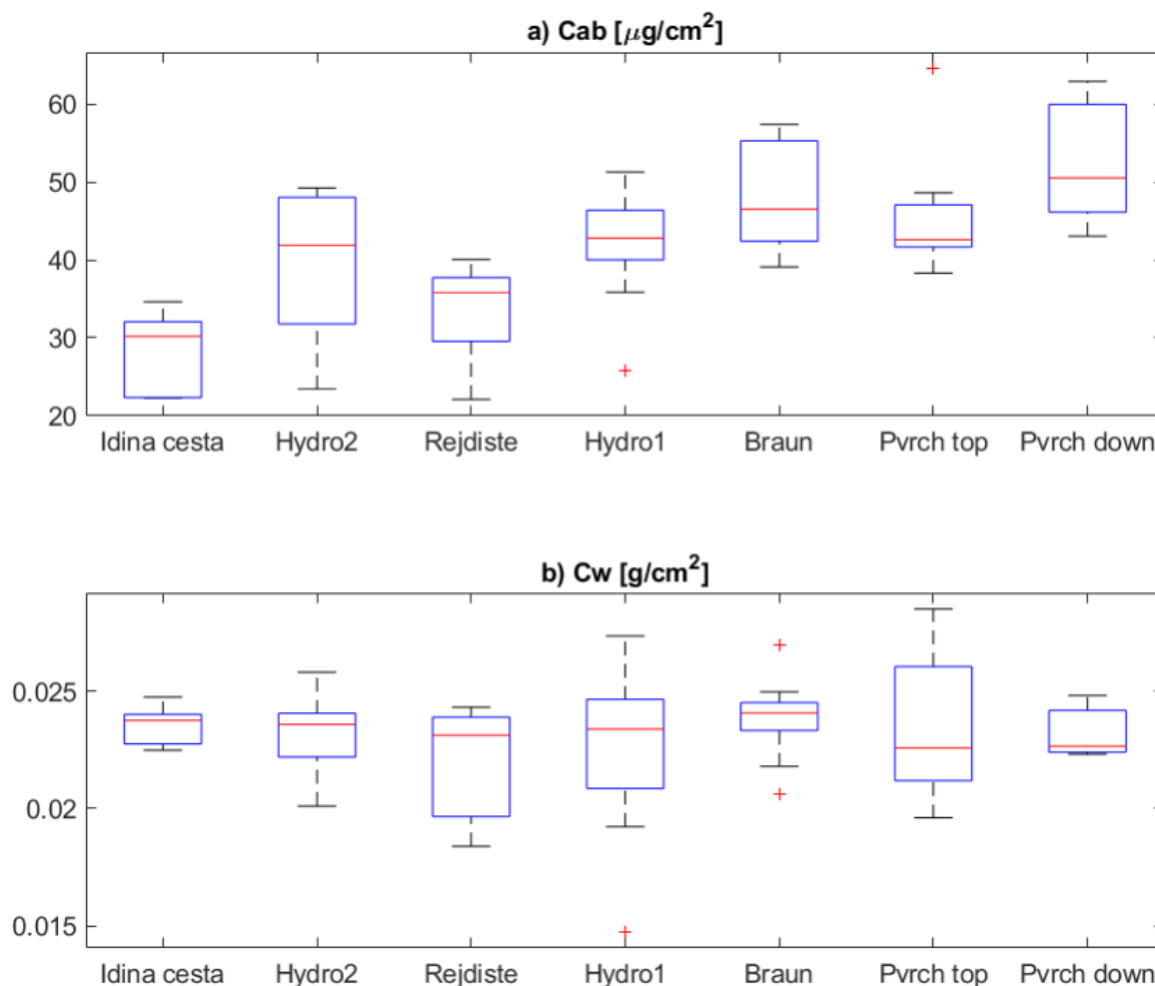
byly extrahovány za tmy při teplotě 4°C po dobu sedmi dnů pomocí N,N-dimethylformamidu (Porra et al., 1989) a jejich obsah byl stanoven spektrofotometricky. Koncentrace pigmentů byly vypočteny podle rovnic uvedených v Wellburn (1994) a vztaženy na jednotku sušiny. Další sada vzorků jehlic byla použita pro stanovení projekční plochy jehlic a hodnocení čerstvé a suché hmotnosti sloužící dále k výpočtu obsahu vody. Projekční plocha jehlic byla přepočítána na polovinu celkové plochy pomocí koeficientů stanovených dle Homolová et al. (2013). Jehlice byly následně vysušeny při 80 °C do konstantní hmotnosti a byla stanovena hmotnost listů na plochu (LMA z anglického leaf mass per area, g.cm²). LMA byla použita pro přepočet pigmentů a obsahu vody (dále jako Cw) z jednotek založených na hmotnosti na jednotky založené na listové ploše.

Vzorky listoví z jednotlivých ročníků pak byly zprůměrovány na celou korunu. Rozdíly mezi jednotlivými plochami v obsahu Cab a Cw jsou znázorněny na obrázku 2. Můžeme pozorovat minimální rozdíly v obsahu vody, větší rozdíly mezi lokalitami jsou pak v obsahu chlorofylu.

Pozice všech dospělých vzorníkových stromů byla zaměřena pomocí terénní GNSS sestavy. Při měření pozic pod korunovým zápojem je přesnost nižší a chyba se pohybuje v řádu desítek cm až jednotek metrů v závislosti na momentální dostupnosti signálu ze satelitů. Pozice vzorníkových stromů slouží k jejich následné lokalizaci na leteckém, potažmo satelitním snímku.



Obrázek 1. Poloha vzorkovaných lokalit v rámci zájmového území povodí. Červené body vyznačují 44 ploch pro stanovení indexu listové plochy (LAI) a modré rámečky vyznačují, 9 ploch pro vzorkování stromů na biochemickou analýzu jehlic.



Obrázek 2. Rozptyl průměrných hodnot obsahu chlorofylu (a) a obsahu vody (b) za strom na vzorkovaných lokalitách.

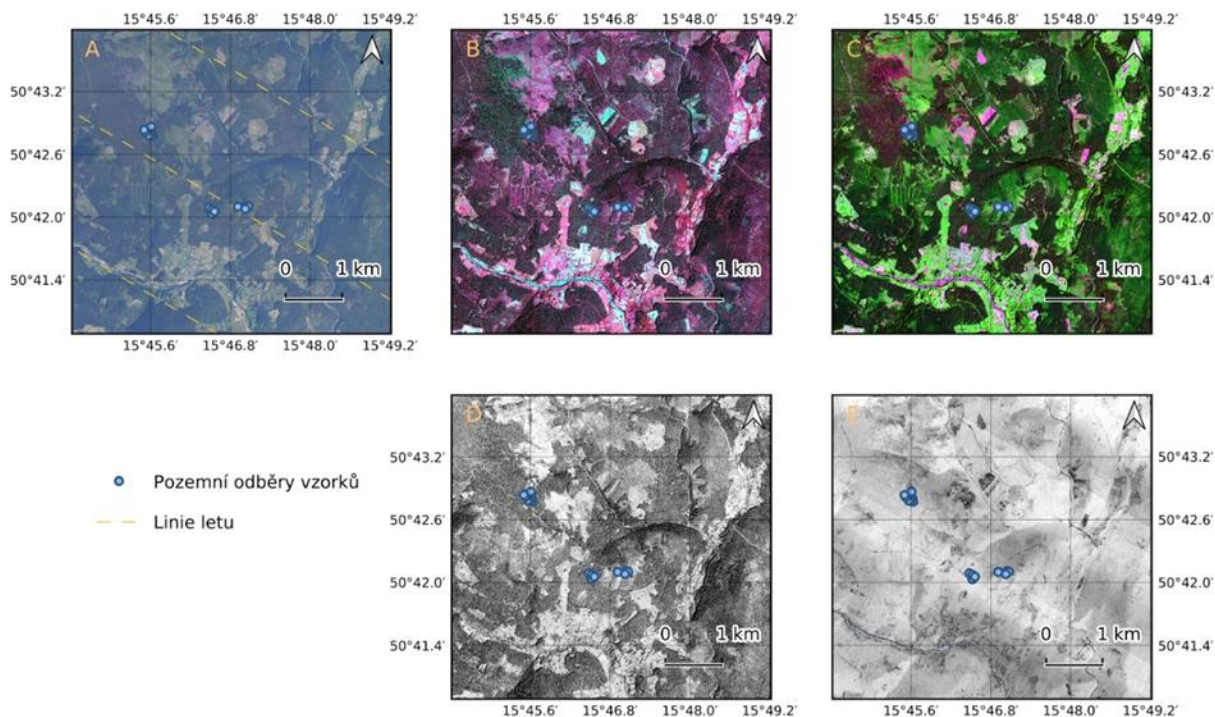
3.2. Letecká obrazová spektroskopie

Data letecké obrazové spektroskopie, neboli hyperspektrální (HS) data byla pořízena leteckou laboratoří FLIS ([Flying Laboratory of Imaging Systems](#)), kterou provozuje Ústav výzkumu globální změny (CzechGlobe). Letecká laboratoř je vybavena spektrometry CASI (snímající ve viditelné a blízké infračervené části elektromagnetického spektra, tj. v rozsahu cca 400 - 1000 nm) a SASI (snímající v krátkovlnné infračervené části elektromagnetického spektra, tj. cca 1000 - 2400 nm). Jelikož oba spektrometry mají různou velikost záznamové matice, při stejné letové hladině a stejném úhlu záběru (40°) snímají spektrometry CASI a SASI data v různém prostorovém rozlišení, proto se při plánované letové kampani vždy zohledňuje několik důležitých faktorů: i) požadavek na prostorové rozlišení výsledných dat; ii) velikost zájmového území; iii) dostatečný překryv letových linií a jejich orientace ve stejném azimutu jako je pozice slunce, čímž se minimalizuje tzv. BRDF (bidirectional reflectance distribution function) efekt v datech, který je způsoben nevhodně zvolenou geometrií mezi sluncem, senzorem a snímaným bodem na zemském povrchu; iv) minimalizace celkového času snímání nad zájmovou lokalitou.

Akvizice leteckých dat proběhla nad zájmovým územím povodí Horní Úpy a oblast Černého Dolu, které náleží k povodí říčky Čistá (cca 90 km²) dne 19. 7. 2022 (v rozmezí 8:34 - 9:19 UTC) za ideálního slunečního počasí bez oblačnosti. Pro takto rozsáhlé území byla zvolena letová hladina cca 4 km nad terénem, z čehož vyplývá prostorové rozlišení CASI dat 2 m na pixel a u SASI dat 5 m na pixel. Následné zpracování HS leteckých dat probíhalo v několika krocích pomocí předzpracovatelského řetězce CzechGlobe:

1. **Radiometrické korekce** obsahují odečtení pozadového šumu (dark subtract) a převod hodnot nasnímaných senzorem (digitální hodnoty) na fyzikálně definované jednotky radiance [$\mu\text{W}\cdot\text{cm}^{-2}\cdot\text{sr}^{-1}\cdot\text{nm}^{-1}$]. Radiometrické korekce jsou prováděny v programu RadCorr Ver. 11.4.1.1 (Itres Ltd.) pomocí laboratorně určených kalibračních parametrů, které jsou určovány pro každý pixel matrice senzoru.
2. **Georeferencování** je provedeno metodou parametrického geokódování za pomoci dat pořízených GNSS/IMU jednotkou letadla a digitálního modelu terénu v programu GeoCor Ver. 3.7.2 (Itres Ltd.). V jednom kroku byly provedeny geometrické korekce, ortorektifikace i georeferencování dat. Pro převzorkování dat do souřadnicového systému UTM (zóna 33N, ETRS-89) byla použita metoda nejbližšího souseda (nearest neighbor).
3. **Sloučení CASI a SASI** dat je prováděno pro georeferencované HS datové kostky CASI a SASI. Vzhledem k vyššímu prostorovému rozlišení senzoru CASI (v tomto případě 2 m) jsou CASI data převzorkována do prostorového rozlišení senzoru SASI (v tomto případě 5 m).
4. **Atmosférické korekce** eliminují vliv atmosféry. Signál odražený od povrchu a změřený leteckým spektrometrem je vždy ovlivněn průchodem tou částí atmosféry, která je v daném okamžiku mezi sluncem, povrchem a senzorem. Hlavními parametry atmosféry, které jsou relevantní pro atmosférické korekce, jsou druh a množství aerosolů a obsah vodních par. To jsou parametry, které významně ovlivňují procházející záření a mohou se v průběhu času měnit. Parametry atmosféry byly odhadnuty přímo z nasnímaných dat. Vlastní výpočet odrazivosti (reflektance) je potom založen na look-up tabulkách generovaných pomocí modelu radiativního transferu. Vlastní atmosférické korekce byly provedeny v programu ATCOR-4 ver. 7.4 (ReSe Application Schlapfler/DLR) s použitím radiativního modelu atmosféry MODTRAN. Pro zvýšení přesnosti absolutních hodnot byla pro atmosférickou korekci využita metoda tzv. "Vicarious" kalibrace. Tato metoda využívá spektrální charakteristiku (odrazivost) vybraného homogenního povrchu, která byla změřena přímo během letecké kampaně v terénu pomocí laboratorního spektrometru (Obrázek 2 ukazuje vybranou kalibrační plochu a příslušné spektrum). Výsledná atmosféricky korigovaná data jsou vyjádřena v hodnotách odrazivosti (reflektance) na úrovni povrchu.
5. **Mozaikování**, tj. spojení jednotlivých linií, bylo provedeno v programu ENVI v. 5.6. Sousedící linie byly navzájem prolнутy pro plynulejší návaznost.

Obrázek 3 ukazuje výřez z plně korigované mozaiky HS dat a spektrálních indexů.



Obrázek 3. Náhledy leteckých hyperspektrálních dat v přiblížení k zájmovým lokalitám podrobnějšího terénního šetření. A - vizualizace dat CASI v pravých barvách RGB v prostorovém rozlišení 2 m; B - vizualizace dat CASI v nepravých barvách (R-858, G-651, B-552 nm) v prostorovém rozlišení 2 m; C - vizualizace spojených CAS-SASI dat v nepravých barvách (R-2082, G-858, B-680 nm) v prostorovém rozlišení 5 m; D - vegetační index PRI (Photochemical Reflectance Index) vyjádřen jako normalizovaný rozdíl vlnových délek 528 a 567 nm poukazující na fotosyntetickou aktivitu vegetace; E - vegetační index TCG (tasseled cap greenness) vyjádřen lineární kombinací šesti spektrálních pásem se střední vlnovou délkou (485, 560, 660, 830, 1650 a 2100 nm) poukazující na variabilitu fotosyntetizující vegetace.

3.3. Satelitní data Sentinel-2

Sentinel-2 je družicová mise programu Copernicus, která poskytuje multispektrální snímky s relativně vysokým prostorovým i spektrálním rozlišením. Hlavní předností Sentinel-2 dat je velikost prostorové rozlišení na úrovni 10 m, 20 m nebo 60 m v závislosti na druhu zaznamenané spektrální oblasti. Sentinel-2 pořizuje snímky ve 13 pásmech pokrývající vlnové délky od viditelného přes blízkou infračervenou oblast až po krátkovlnnou infračervenou oblast (400 - 2500 nm) (tabulka 1). Snímkovací frekvence díky dvojici družic 2A a 2B umožňuje globální pokrytí stejného místa každých 5 dní.

K analýze krátkodobých trendů zdravotního stavu lesů v zájmovém území povodí horní Úpy a horní Čisté byly použity snímky Sentinel-2A a 2B v období 2017 až 2024. Kvůli optické povaze dat a poloze zájmové lokality dochází k častému zakrytí scény různým typem oblačnosti, což znemožňuje použití velkého množství snímků pro analýzy stavu a vývoje změn krajinného pokryvu. Z tohoto důvodu byly nejprve vytvořeny roční bezoblačné kompozity, zahrnující letní pozorování mezi 1.6. a 30.8. Příprava bezoblačných kompozitů byla plně automatizována v prostředí cloudového zpracování dat Google

Earth Engine (Gorelick et al., 2017). Během tohoto procesu byl vypočítán medián odrazivosti povrchu nad snímky, na které byla též aplikována maska oblačnosti. Výsledkem je časová řada sedmi snímků, zachycující medián odrazivosti povrchu v zájmovém území v období vegetačního maxima pro každý rok 2017 - 2024.

Tabulka 1. Spektrální a prostorové rozlišení jednotlivých spektrálních pásem Sentinel-2A a Sentinel-2B (zkratky: NIR - blízká infračervená oblast spektra z anglického near infrared, SWIR - krátkovlnná infračervená oblast spektra z angl. shortwave infrared).

Spektrální pásmo	Hlavní použití	Sentinel-2A		Sentinel-2B		Velikost pixelu. (m)
		Střední vl. délka (nm)	Šířka pásma (nm)	Band number	Main purpose	
Band 1	Coastal aerosol	442.7	21	442.2	21	60
Band 2	Blue	492.4	66	492.1	66	10
Band 3	Green	559.8	36	559	36	10
Band 4	Red	664.6	31	664.9	31	10
Band 5	Vegetation red edge	704.1	15	703.8	16	20
Band 6	Vegetation red edge	740.5	15	739.1	15	20
Band 7	Vegetation red edge	782.8	20	779.7	20	20
Band 8	NIR	832.8	106	832.9	106	10
Band 8A	Narrow NIR	864.7	21	864	22	20
Band 9	Water vapour	945.1	20	943.2	21	60
Band 10	SWIR – Cirrus	1373.5	31	1376.9	30	60
Band 11	SWIR	1613.7	91	1610.4	94	20

4. Metodický postup

4.1. Spektrální indikátory odvozené z letecké obrazové spektroskopie

Z korigovaných leteckých hyperspektrálních dat CASI-SASI v prostorovém rozlišení 5 m byly vypočteny dvě sady chemických indikátorů. První sadou tvoří indikátory stavu vegetace, konkrétně obsah fotosynteticky aktivních pigmentů chlorofylu a+b (dále Cab) a obsah vody v listoví (dále Cw), které byly vypočteny z empirické kalibrace leteckých dat pomocí pozemních měření. Druhou sadou jsou hyperspektrální vegetační indexy citlivé na obsah vody, obsah fotosyntetických pigmentů a celkové zelenosti vegetace. Metodický postup výpočtu spektrálních indikátorů zdravotního stavu lesa z leteckých HS dat je znázorněn na obrázku 4.

Empirické odhady biochemických indikátorů

První přístup využívá data pozemních odběrů biochemických charakteristik listového aparátu smrku ztepilého ke kalibraci leteckých HS dat. Pro výpočet obsahu Cab byly vybrány spektrální pásma ve viditelné a blízké infračervené oblasti, tzv. red-edge oblasti, kde dochází k absorpci světla fotosynteticky aktivní pigmenty. Do analýzy vstupovalo 16 pásem v rozsahu 545 až 723 nm. Pro výpočet Cw byly vybrány spektrální pásma ve viditelné, blízké i krátkovlnné infračervené oblasti. Do analýzy vstupovalo 31 pásem v rozsahu 545 až 2157 nm, v daném rozsahu byla vyřazena spektra s malým odstupem signálu a šumu, kde nebylo možné provést atmosférické korekce s náležitou přesností.

Datová sada pozemních odběrů biochemických vlastností listoví byla použita jako další vstupní vrstva. Měření na úrovni jednotlivých ročníků jehlic byla zprůměrována na hodnoty za jeden strom. Terénní měření pozic jednotlivých vzorkovaných stromů byla použita k lokalizaci odběrných míst na HS snímku. Prostorové rozlišení 5 m neumožňovalo detekci jednotlivých stromů, proto byl zvolen kruh o poloměru 10 m, ze kterého byla extrahována průměrná spektrální odrazivost v místě odběru. Další podmínkou pro zařazení obrazových pixelů z leteckých HS dat do analýzy byla podrobná maska lesa. Ta byla vytvořena pomocí digitálního modelu povrchu z leteckých lidarových dat, ze které byly vyfiltrovány pixely s výškou menší než 4 m nad terénem a na základě spektrální odezvy byly odstraněny pixely s nízkou hodnotou signálu zpravidla způsobené stíny a mezerami mezi korunami stromů. Průměrná spektra splňující podmínky a průměrné hodnoty biochemických parametrů za jednotlivé stromy, byly použity pro vytvoření lineárního regresního modelu. Celkově do modelu vstupovalo 54 vzorků.

Pro trénování modelu byla zvolena metoda Partial Least-Squares Regression. Natrénovaný regresní model vysvětluje závislost mezi odhadem obsahu chlorofylu z leteckých dat a laboratorní analýzou odebraných vzorků vysvětloval 61.8% rozptylu hodnot ($R^2 = 0.618$). U závislosti mezi odhadem obsahu vody z leteckých dat a obsahem vody naměřených při laboratorní analýze vysvětloval nižší procento rozptylu, a to 58.8% ($R^2 = 0.588$).

Hyperspektrální vegetační indexy

Výpočet HS vegetačních indexů je relativně jednoduchý postup využívající kombinace různých spektrálních pásem. Důležitý je výběr vhodných indexů, které jsou citlivé vůči různým charakteristikám vegetace. Pro analýzu stavu lesních porostů jsme zvolili následující tři spektrální indexy:

Moisture Stress Index (MSI) je index senzitivní vůči obsahu vodu v listoví a využívá vlnové délky v oblastech absorpce vody v blízké a krátkovlnné infračervené oblasti (Ceccato et al., 2001). Vyšší hodnoty indexu naznačují nižší obsah vody ve vegetaci.

$$MSI = R_{1599} / R_{819}$$

Carotenoid Reflectance Index (CRI) je index senzitivní vůči obsahu fotosynteticky aktivních pigmentů a poměru obsahu chlorofylu vůči karotenoidům a využívá spektrální pásma v zelené části elektromagnetického spektra (Gitelson, 2002). Vyšší hodnoty indexu indikují vyšší obsah karotenoidů vůči chlorofylu.

$$CRI = 1/R_{510} - 1/R_{550}$$

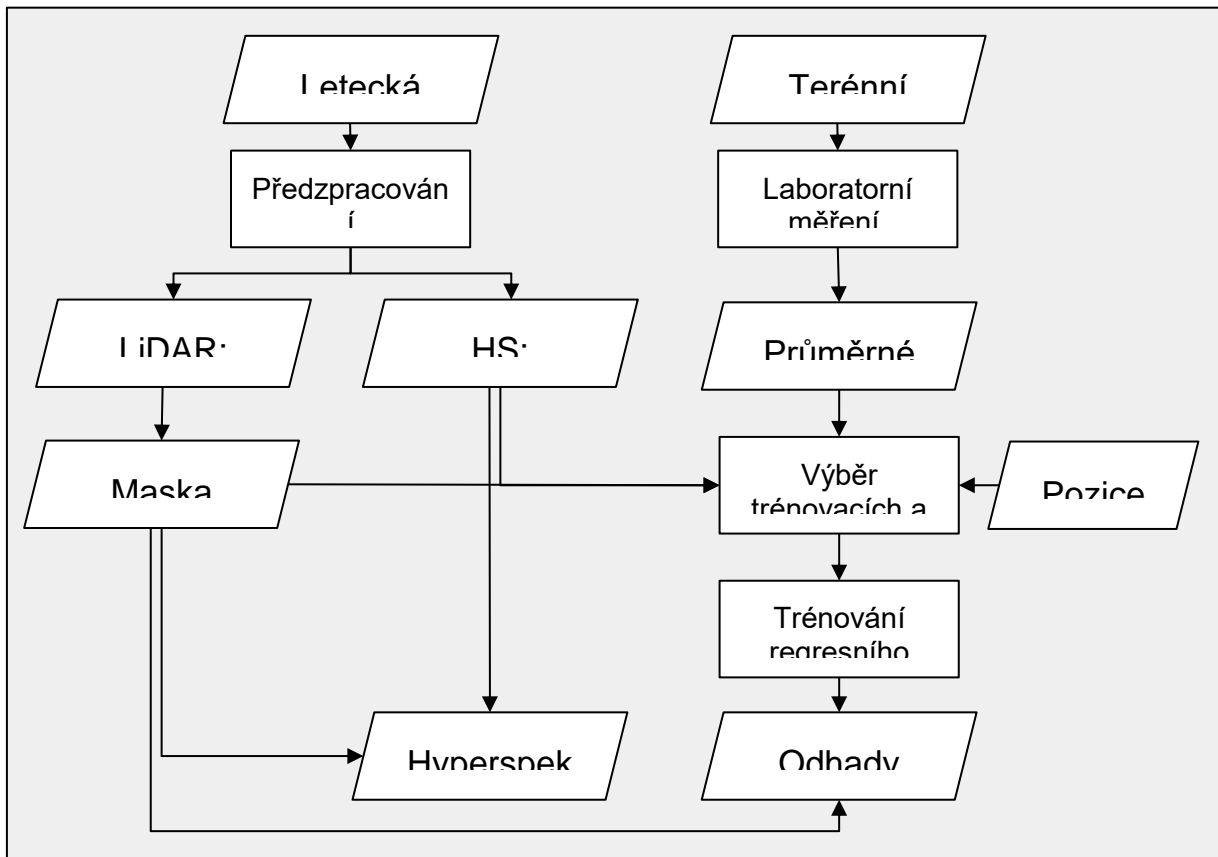
Enhanced Vegetation Index (EVI) je původně multispektrální index vyvinutý pro MODIS data, který je citlivý na hustotu vegetace, nebo-li index listové plochy (Huete et al., 2002).

$$EVI = 2.5 * (NIR - Red) / (NIR + 6*Red - 7.5*Blue + 1)$$

V tomto konkrétním případě leteckých hyperspektrálních dat byly použity tyto vlnové délky NIR = R₈₀₁, Red = R₆₈₀, Blue = R₄₅₂.

Vegetační indexy byly vypočteny pomocí nástroje Vegetation Analyst v programu ENVI 5.7.

Pro další analýzy byly tyto tři indexy zkombinovány do RGB kompozice v nepravých barvách, kdy každý z indexů byl načten do jednoho barevného kanálu.



Obrázek 4. Pracovní diagram empirických odhadů biochemických indikátorů a výpočtu vegetačních indexů z leteckých hyperspektrálních (HS) dat.

4.2. Krátkodobé trendy spektrálních indikátorů ze satelitních dat Sentinel-2

Bezoblačné roční kompozity satelitních snímků (Sentinel-2) pro zájmové území v letech 2017 - 2024 byly použity k výpočtu spektrálního indexu "Disturbance Index" (DI) dle Haeley et al. (2005). Výpočet DI a krátkodobých trendů ze Sentinel-2 multispektrálních dat je znázorněn na obrázku 5. Výpočet indexu je založen na tzv. Tasseled Cap transformaci, která počítá komponenty *Brightness* (dále B), *Greenes* (dále G) a *Wetness* (dále W) jako lineární kombinaci šesti Sentinel-2 pásem (B2, B3, B4, B8A, B11 a B12) dle následujících rovnic:

$$B = 0.3510 \cdot B2 + 0.3813 \cdot B3 + 0.3437 \cdot B4 + 0.7196 \cdot B8A + 0.2396 \cdot B11 + 0.1949 \cdot B12,$$

$$G = -0.3599 \cdot B2 - 0.3533 \cdot B3 - 0.4734 \cdot B4 + 0.6633 \cdot B8A + 0.0087 \cdot B11 - 0.2856 \cdot B12,$$

$$W = 0.2578 \cdot B2 + 0.2305 \cdot B3 + 0.0883 \cdot B4 + 0.1071 \cdot B8A - 0.7611 \cdot B11 - 0.5308 \cdot B12.$$

Jednotlivé komponenty byly následně normalizovány pomocí průměrů (μ) a směrodatných odchylek (σ), které byly vypočteny pouze nad pixely lesa v rámci zájmového území, následovně:

$$Br = (B - B\mu) / B\sigma,$$

$$Gr = (G - G\mu) / G\sigma,$$

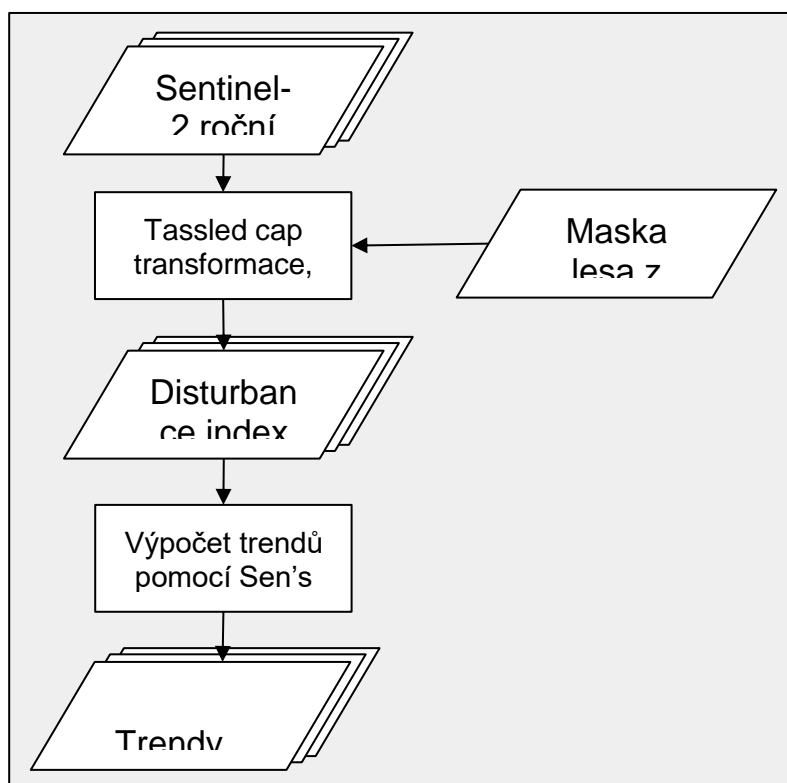
$$Wr = (W - W\mu) / W\sigma.$$

Z těchto normalizovaných komponent se finálně vypočetl DI pro každý rok následujícím způsobem:

$$DI = Br - (Gr + Wr).$$

Obecně lze říci, že vysoké hodnoty DI poukazují na výskyt disturbance v porostu jako je těžba, kde se spektrálně projeví holá půda, či mrtvé stromy, u kterých došlo výrazné barevné změně koruny.

Krátkodobé trendy DI pro různá období (2017 - 2022, 2017 - 2023 a 2017 - 2024) byly vypočteny jako sklon regresní přímky časové řady indexu DI pomocí neparametrické Theil-Senovy regrese (též jako Senův sklon z angl. Sen's slope). Ve srovnání s běžnou lineární regresí metodou nejmenších čtverců je tato metoda méně citlivá na případné odchylky od normálního rozdělení včetně odlehlých hodnot. Výpočet DI a krátkodobých trendů pro výše zmíněné časové úseky byl opět plně automatizován v prostředí Google Earth Engine. Následně byly výstupy uloženy ve formátu tiff a použity v prostředí Qgis pro další analýzy.



Obrázek 5. Pracovní diagram výpočtu disturbance indexu a krátkodobých trendů z družicových dat Sentinel-2.

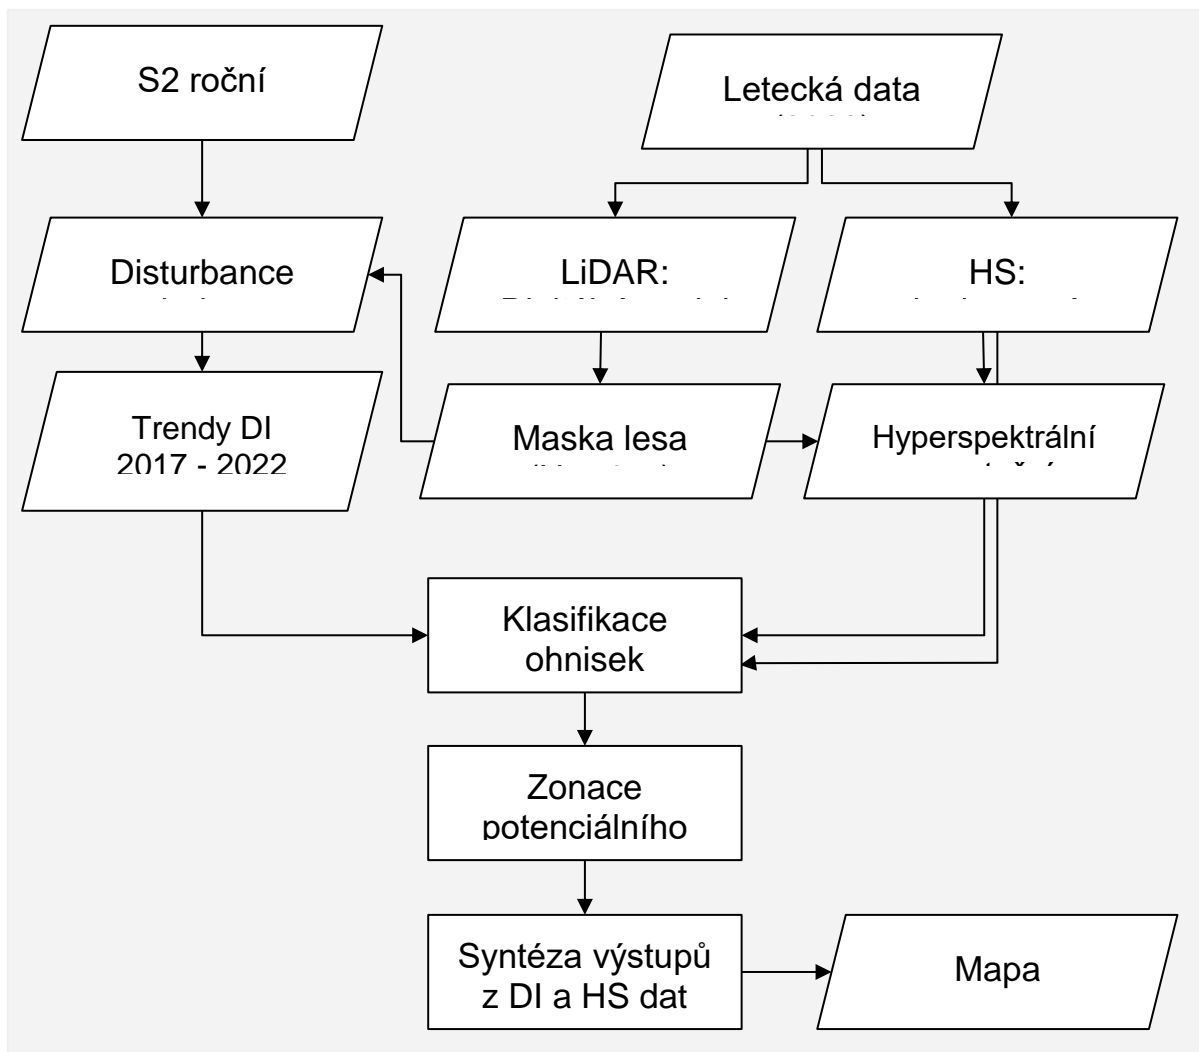
4.3. Identifikace postižených a výrazně ohrožených porostů

Identifikace a vymezení postižených/ohrožených prostor je v našem případě chápána jako syntéza výsledků metod popsanych v předchozí kapitolách 4.1. a 4.2. (viz obrázek 6). Propojení obrazových dat z různých prostředků, ať již ze satelitu nebo leteckého HS senzoru, umožní získat informace, které není možné uvažovat při použití jednoho zdroje dat samostatně.

V syntéze využíváme základních výhod jednotlivých typů dat, ze které potom logicky vychází i celá syntéza. V našem případě jsou satelitní data Sentinel-2 chápána jako nástroj pro monitoring stavu na lokalitě v časovém horizontu několik let, umožňující sledovat trend vývoje. To vše se odehrává v relativně hrubém prostorovém měřítku (20 x 20 m) umožňujícím lokalizaci nejvýraznějších a prostorově nejrozsáhlejších změn v porostech. Pro podrobnější prostorovou lokalizaci a identifikaci méně prostorově výrazných jevů využíváme letecká HS data. Ta, díky svému vyššímu prostorovému rozlišení (5 x 5 m) umožňují postihnout změny odehrávající se na menší ploše. A jejich spektrální rozlišení umožní vyhodnotit i spektrálně méně výrazné změny v porostech. Navíc při jejich pořízení vznikají i data lidarová, která po zpracování poskytnou informaci o výšce povrchu. Tato informace slouží jako velmi vhodný podklad pro přesné vymezení oblastí lesa, které se využije v další analýze jak leteckých, tak satelitních dat. Pro vymezení lesních porostů byl použit práh ve výšce 4 m nad terénem, který tak odstranil povrchy jako louky, paseky sjezdové tratě atd.

V prvním kroku jsou určeny ohniska poškození porostu jak z leteckých, tak satelitních dat. Jedná se o identifikaci stojících mrtvých či odumírajících stromů, jejichž koruna doznala barevných změn (reznutí či opad jehlic). Klasifikace byla provedena jak z leteckých HS dat, tak z trendů DI. v případě leteckých dat vstupovala do klasifikace vrstva korigované reflectance. Trénovací oblasti byly manuálně vybrány operátorem na základě znalosti poškozených stromů z terénu a za pomoci leteckých dat CASI ve vyšším prostorovém rozlišení (2 m), díky němuž lze lépe identifikovat jednotlivé stromy. Metodou rozhodovacího stromu (angl. decision tree) byla naténována řízená klasifikace. Metoda rozhodovacích stromů byla zvolena z důvodu, že na trénovacích datech dosahoval vysoké úspěšnosti klasifikace (97,5%) při odlišení zdravých a poškozených stromů. Takto byla identifikována i menší ohniska (jednotlivci či skupinky několika stromů) odumírajících či odumřelých stromů, ze kterých se může poškození šířit v následujících letech dál. V případě satelitních dat jsme ohniska identifikovali pomocí prahování trendů DI. Jako ohniska poškození byly klasifikovány plochy s hodnotou sklonu DI > 0.5.

V druhém kroku uvažujeme prostorové schéma šíření, kdy nejohroženějším místem jsou prostory bezprostředně sousedící s identifikovaným místem poškození lesa. Okolo místa poškození (disturbance) budujeme několik obalových zón, a to ve vzdálenostech 25 m, 50 m a 100 m od kraje disturbance (okraje pixelu). Epicentrum a obalové zóny jsou vytvořeny z klasifikace hodnoty trendů DI ze satelitních dat. Klasifikace poškozených stromů na základě HS dat je přidána následně a slouží k potvrzení výskytu disturbance detekované satelitními daty a k dopřesnění malých, začínajících disturbancí, které pro svůj rozsah satelitní data nezachytily.



Obrázek 6. Pracovní diagram celého řetězce stanovení poškození lesních porostů.

5. Výsledky

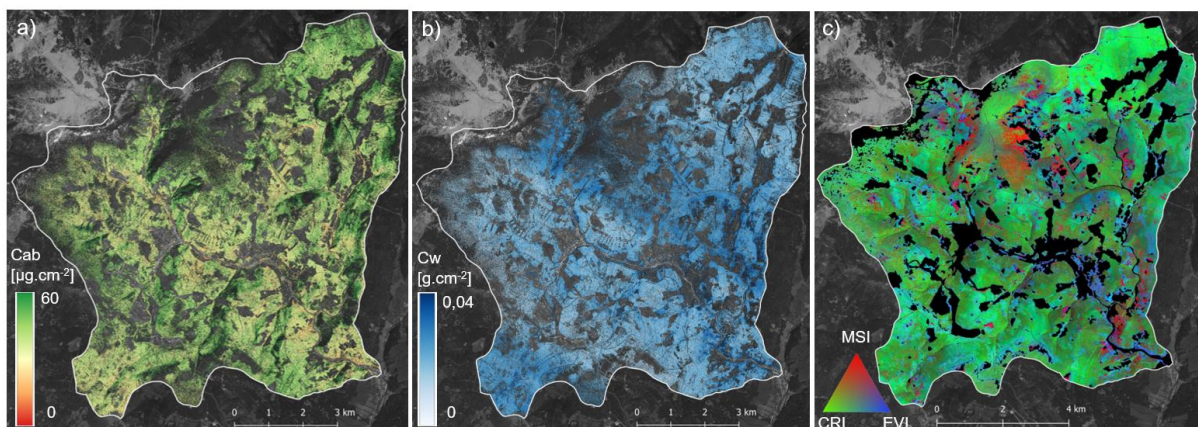
5.1. Spektrální indikátory odvozené z letecké obrazové spektroskopie

Z hyperspektrálních leteckých dat byly odvozeny dva typy indikátorů: i) biochemické parametry listoví (obsah pigmentů a obsah vody) odvozené z pozemních šetření (obrázek 7a,b) a ii) syntéza vybraných HS indexů (MSI, CRI a EVI) (obrázek 7c). I když hodnoty biochemických indikátorů jsou v rozsahu očekávaných hodnot, statistické modely vysvětlovaly jen kolem 60% rozptylu hodnot. Variabilita v odhadech Cab spíše kopírovala věkové rozložení porostů, variabilita v rámci Cw byla minimální a

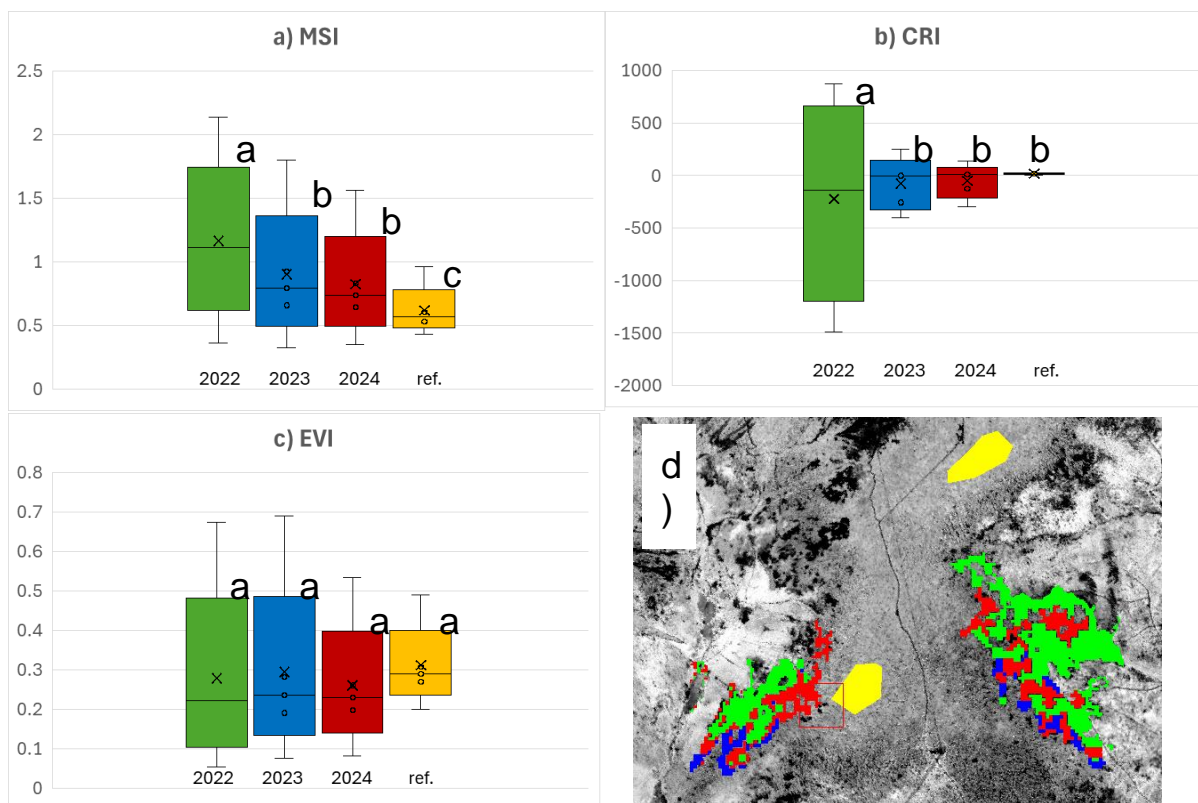
bohužel vykazovala nedostatky při atmosférických korekcích a mozaikování leteckých HS dat. Spolehlivost odhadů biochemických indikátorů byla bohužel nízká. Nebyly zjištěny statisticky významné rozdíly mezi referenčním "zdravým" porostem a porosty náchylnými k rozpadu v následujících letech (viz obrázek 8d a 10), jako tomu bylo například u spektrálního indexu MSI (obrázek 8a). Statisticky významné rozdíly mezi jednotlivými skupinami porostů byly pozorovány pouze u indexu MSI ($\alpha = 0,05$), u dalších spektrálních indexů byly rozdíly statisticky nevýznamné (obrázek 8).

Bohužel, při analýze leteckých HS dat se ukázalo, že předzpracování a atmosférické korekce nad takto rozsáhlým, topograficky členitým územím se specifickým vegetačním pokryvem, není jednoduché. I když HS letecká data pořízená v prostorovém rozlišení 5 m poskytují detailnější pohled na zdravotní stav porostů, každopádně velikost rozlišení vzhledem k typu převažujících smrkových porostů neumožňuje monitorovat situaci na úrovni jednotlivých stromů, ale je využitelná na úrovni skupin stromů. Tento přístup umožňuje detekovat začínající poškození od skupinek 2 - 3 stromů, závisící na jejich velikosti. Nedostatkem leteckých dat v tomto prostorovém rozlišení bylo ovlivnění některých pixelů stíny a neosvětlenými mezerami mezi stromy především v případech, kdy jejich velikost byla poloviční ve srovnání s prostorovým rozlišením pořízených snímků. I když na data byla aplikována maska výšek povrchu, aby odstranila prosvítající mezery a povrchy cest mezi stromy, jevy odehrávající se uvnitř plochy jednoho pixelu nelze uspokojivě odstranit.

Další nepřesnosti do odhadů reflektance na úrovni povrchu vnesly atmosférické korekce snímků v členitém horském terénu, kde se projeví rozdíly mezi údolím a vrcholem hor, a mezi osluněnými a zastíněnými svahy. Všechny tyto nepřesnosti se pak následně přenášely do odhadů biochemických indikátorů a částečně pak i do výpočtu HS indexů.



Obrázek 7. Indikátory zdravotního stavu lesních porostů odvozené z hyperspektrálních leteckých dat. Obsah chlorofylu (a) a obsah vody (b) v listoví je odvozen pomocí statistického modelu, který byl kalibrován na datech pozemního šetření. Barevná syntéza tří spektrálních vegetačních indexů (c) Moisture Stress Index - MSI, Carotenoid Reflectance Index - CRI a Enhanced Vegetation Index - EVI.

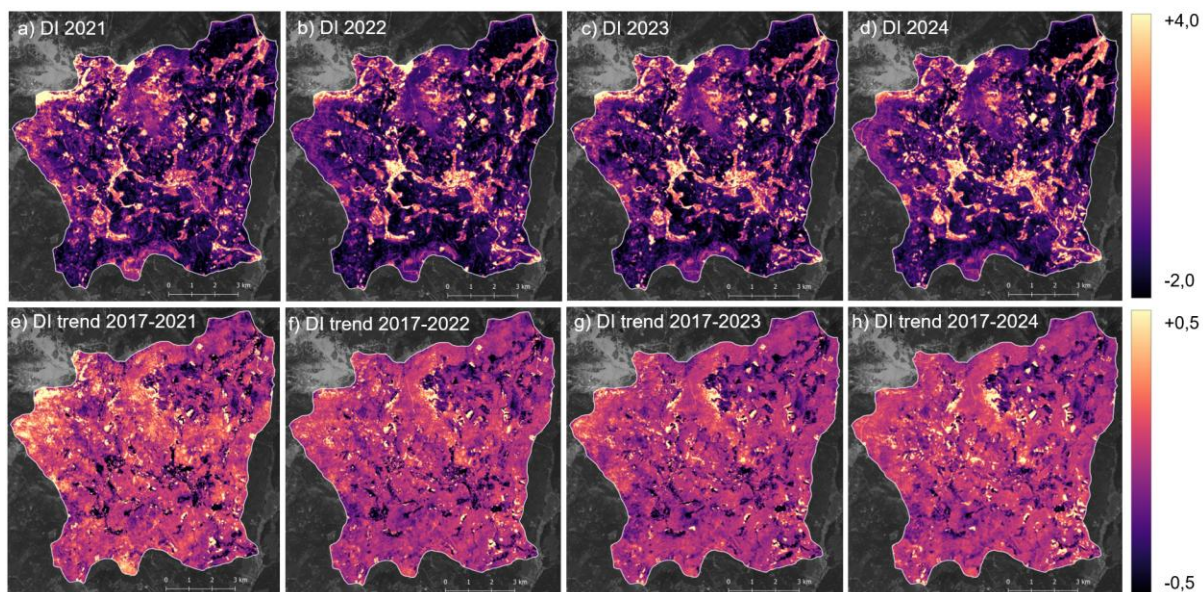


Obrázek 8. Boxploty ukazují rozptyl hyperspektrálních vegetačních indexů (a) Moisture Stress Index MSI, (b) Carotenoid Reflectance Index (CRI), (c) Enhanced Vegetation Index EVI vypočtených z leteckého snímku z r. 2022 nad polygony postupného šíření odumírání lesních porostů v oblasti Růžové hory (d). Polygony šíření v jednotlivých letech byly určeny z Disturbance indexu (DI) ze Sentinel-2 snímků. Zeleně odumřelé stromy v r. 2022, modře v r. 2023, červeně v r. 2024 a žlutou barvou vyznačeny polygony relativně zdravých a věkově podobných porostů, kde ve sledovaném období nebyly pozorovány změny DI. Rozdílná písmena nad boxploty značí významný rozdíl v průměrné hodnotě indexu mezi jednotlivými polygony.

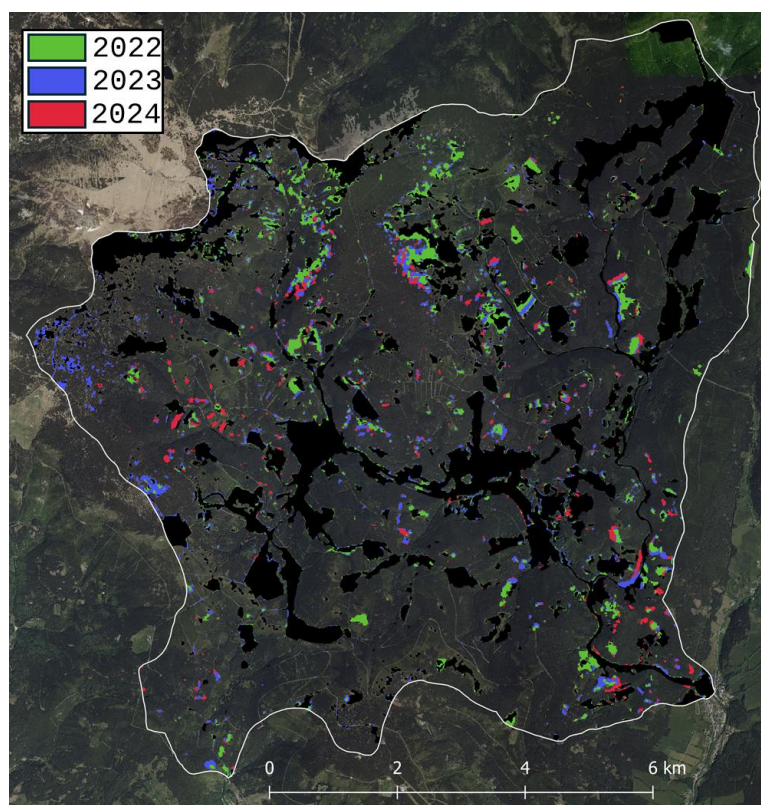
5.2. Krátkodobé trendy spektrálních indikátorů ze satelitních dat Sentinel-2

Z družicových dat Sentinel-2 byl vypočten DI pro jednotlivé roky (obrázek 9a-d) a následně byl spočítán trend (sklon směrnice) DI za různé časové úseky (obrázek 9e-h). Na první pohled nejsou rozdíly mezi jednotlivými roky zřejmé, avšak právě možnost sledování vývoje změn v čase, umožňuje identifikovat vznik disturbancí na roční bázi (obrázek 10). Krátkodobé trendy DI se prokázaly jako účinný nástroj při mapování disturbancí většího rozsahu, jednalo o disturbance na ploše větší než 40 x 40 m. Je však nutné zmínit, že DI je méně citlivý vůči detekci již poškozených částí lesa, kde začala probíhat sukcese. Podstata DI neumožňuje odlišit typ poškození lesa, ať se jedná o odumírání stromů v důsledku např. napadení kůrovcem či plánovaná těžba. Obě tyto události byly identifikovány jako disturbance s vysokou hodnotou DI či sklonu trendu. Právě pro vyloučení disturbancí v důsledku těžby je vhodné přidat vrstvu výšek porostu odvozených z leteckých lidarových dat, které spolehlivě odliší úbytek lesa od odumřelých stojících stromů.

Jak syntéza HS indexů v nepravých barvách, tak i DI odvozen z dat satelitních, poměrně shodně identifikovala oblasti lesa s výrazným poškozením, avšak letecká data díky vyššímu prostorovému rozlišení lépe dokázala identifikovat menší skupinky odumírajících stromů (obrázek 11).



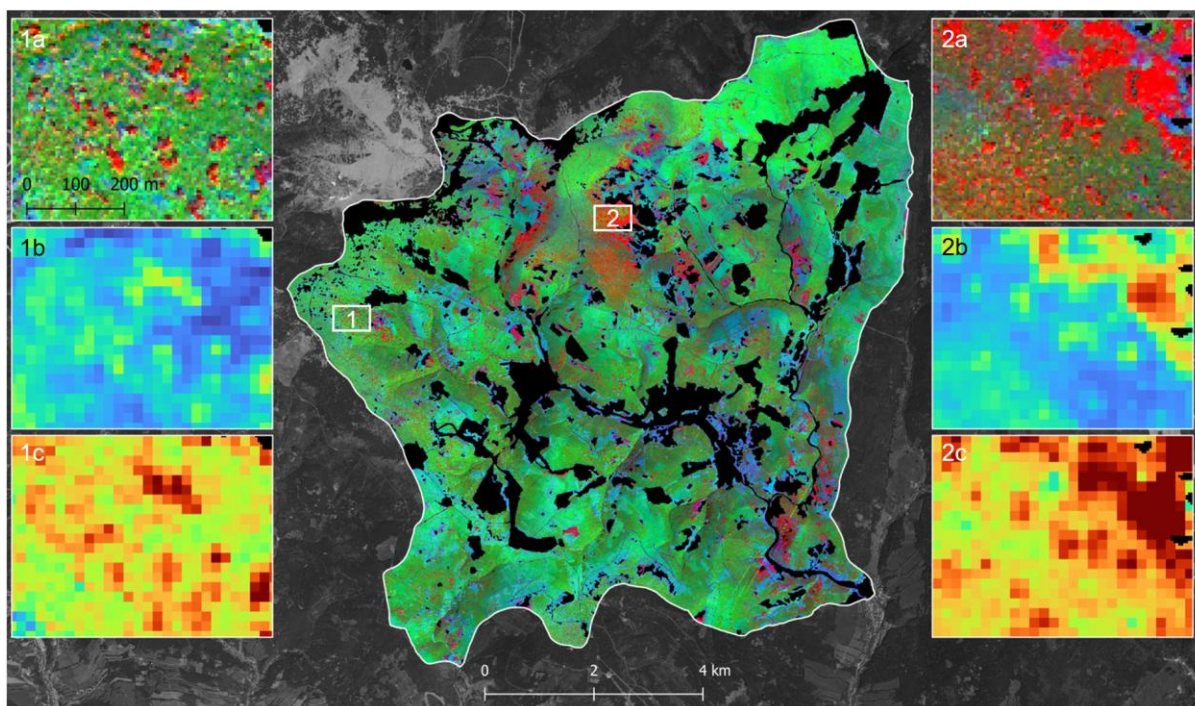
Obrázek 9. Vývoj hodnot distrubance indexu (DI) pro roky 2021 až 2024 (a-d) a krátkodobého trendu od roku 2017 (e-h) v zájmovém území povodí horní Úpy a horní Čisté.



Obrázek 10. Meziroční šíření disturbancí v lesních porostech, primárně způsobených těžbou a odumíráním lesa v jednotlivých letech 2022 až 2024. Jedná se o plochy s vysokou hodnotou disturbance indexu ($DI > 2.0$) v jednotlivých letech.

5.3. Identifikace poškozených porostů a porostů náchylných k dalšímu poškození

Pro vyznačení oblastí s již započatou distrubancí byly zvoleny tři přístupy: i) vizuální interpretace pomocí barevné syntézy vybraných HS vegetačních indexů, ii) klasifikace založená na prahování trendu DI, a iii) klasifikace leteckých HS dat. Každý z výše zmíněných přístupů nabízí uživateli informace o zdravotním stavu vegetace jinou formou. Výběr zobrazení záleží na preferencích uživateli a řešené úloze. Barevná syntéza vegetačních indexů (Obrázek 11) klade vyšší nároky na použité zobrazovací zařízení, proto není vhodná na využití na mobilních zařízeních přímo v terénu. Poskytuje ale úplný (neprahovaný) pohled na data, které si lze velmi přesně propojit. Na obrázku 11 je uvedena identifikace poškození lesních porostů za pomoci barevné syntézy vybraných HS vegetačních indexů z leteckých dat. Pro příklad byly vybrány dvě oblasti označeny v obrázku 11 jako 1 a 2, na kterých oba zdroje dat DPZ identifikovali poškození. Obrázky 11b,c byly získány analýzou satelitních dat v prostorovém rozlišení 20 m na pixel a zobrazují obecný přehled dlouhodobé situace na místech poškození a v jejich okolí. Výřezy 1a, 2a ukazují barevnou syntézu tří vybraných HS indexů ve vyšším prostorovém rozlišení 5 m. Prostorové rozlišení 5 m umožní detailnější zhodnocení narušení malého prostorového rozsahu, které satelitní data svým prostorovým rozlišení neodhalí. Navíc umožní identifikovat malá začínající místa odumírání v okolí velkých disturbancí, která mají do budoucna vysoký potenciál rozšíření. Příklady na obou zvolených místech 1 i 2 dokumentují potenciál využití právě v okolí velkých disturbancí.



Obrázek 11. Barevná kompozice hyperspektrálních vegetačních indexů (červený kanál = MSI, zelený kanál = CRI, modrý kanál = EVI). Místa označená jako 1 a 2 ukazují podrobnější detail, který lze identifikovat z leteckých dat v prostorovém rozlišení 5 m (vnořené obrázky 1a a 2a). Červenou barvou jsou zvýrazněny odumřelé a prosychající porosty. Obrázky 1b a 2b zobrazují absolutní hodnoty DI z roku 2022 ze Sentinelu-2 v prostorovém rozlišení 20 m. Obrázky 1c a 2c zobrazují hodnotu trendu DI v období 2017 - 2022 opět v prostorovém rozlišení 20 m.

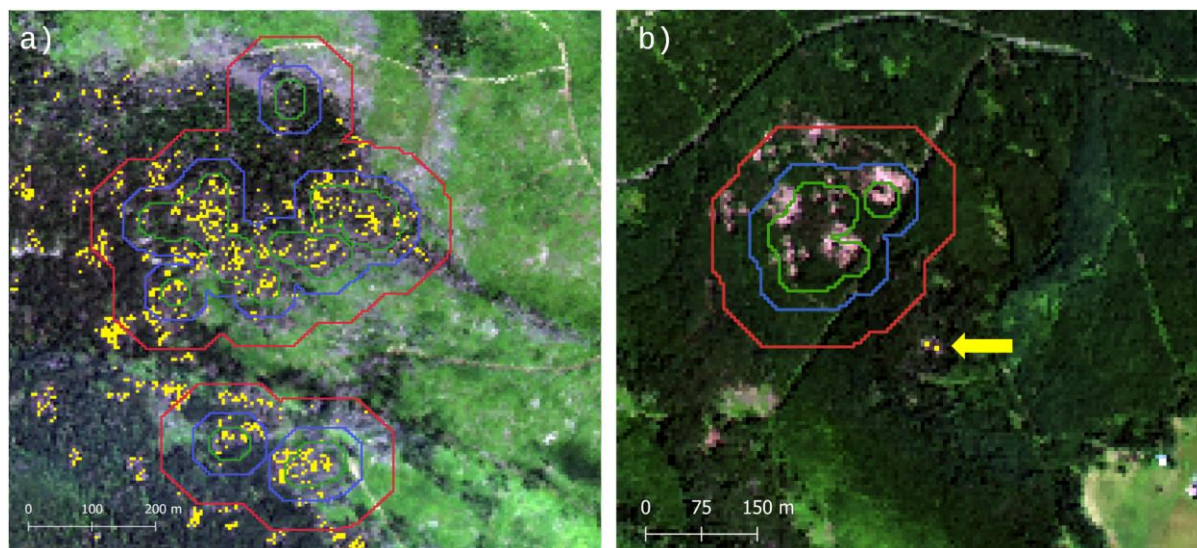
Pro potřeby terénních pracovníků a prací přímo v terénu byla využita metoda obalových křivek, která od nalezeného epicentra detekovaného satelitními daty vytvoří obalové křivky ve vzdálenosti 25 m, 50 m a 100 m. Na obrázku 12 jsou současně zaneseny bodové oblasti (pixely) detekované jako usychající stromy klasifikované z HS dat, které tak poskytují uživateli informaci ve větším detailu než výše zmíněné zóny navázané na satelitní data.

Potvrzení míst výskytu disturbance z obou typů dat je důležitým předpokladem pro eliminaci falešné detekce odumírajícího lesa. Na obrázku 12a je uveden příklad, kdy se oba zdroje dat shodují na identifikaci poškození lesního porostu a zatímco satelitní data zachycují situaci v nejvýrazněj poškozených místech, letecká data identifikují i poškození mimo zónami vymezené okolí, které bude potřeba v praxi navštívit a zkontrolovat.

Na obrázku 12b je uveden příklad falešné detekce poškození ze satelitních dat. V tomto případě satelitní data identifikovala místa řízené těžby většího rozsahu, letecká data tuto identifikaci správně nepotvrdila. Naopak za pomoci leteckých dat byly identifikovány malé oblasti poškození v okolí (ukázané žlutou šipkou), které se do budoucna mohou zvětšovat.

Nevýhodou zvoleného přístupu je nutnost precizního nastavení parametrů klasifikace, tak aby nevznikaly falešně pozitivní detekce. To sebou nevyhnutelně nese podhodnocení počtu detekovaných pixelů a velikosti oblastí odumírání. Cílem prahovám v našem případě nebylo záměrně podhodnocovat počet a velikost poškozených oblastí v lesních porostech, ale za pomoci prahu zamezit falešným detekcím a vytvořit mapu více srozumitelnou a spolehlivou. Koncový uživatel těchto map by měl tyto

předpoklady znát a pracovat s nimi třeba za pomoci využití barevných syntéz, které umožňují uživateli utvořit si vlastní úsudek na základě neprahované informace.



Obrázek 12. Ukázka vymezení zón ohrožení rozpadem lesních porostů. Ohniska jsou detekována na základě trendu disturbance indexu (DI) z období 2017 - 2022 a pomocí jednoduchých izočar jsou vymezeny zóny potenciálního rozpadu lesa v následujících letech (vzdálenost 25 m od ohniska zeleně, 50 m modře a 100 m červeně). V prvním případě (a) se jedná o mrtvé stromy a odumírající les, avšak v druhém případě (b) DI identifikoval menší holiny vzniklé pravděpodobně v důsledku řízené těžby, které primárně nesouvisí s poškozením stromů napadených kůrovcem. Prostorové rozlišení DI 20 m však neumožňuje zachytit menší shluk odumírajících stromů (ukázáno žlutou šipkou), což dokáží data leteckého průzkumu díky svému vyššímu prostorovému rozlišení. Žlutě jsou pak vyznačeny pixely poškozených stromů identifikovaných klasifikací hyperspektrálních leteckých dat.

6. Závěr

Cílem metodiky bylo vytvoření postupů umožňujících s pomoci dat DPZ zmapovat zdravotní stav lesa a jeho změny na území Krkonošského národního parku. Území parku patří svou rozlohou a obtížně přístupným terénem mezi území v rámci České republiky, kde je uplatnitelnost běžně používaných postupů (tj. lesní obchůzky) pro kontrolu zdravotní stavu obtížná. Kromě náročného terénu s velkými převýšeními zde důležitou úlohu hraje i personální kapacita, která neumožňuje provést kompletní kontrolu zdravotního stavu lesa ve všech částech parku v krátkém čase. Navržená metodika přihlíží k těmto omezením a navrhuje přístup, který při využití současných personálních zdrojů umožní monitorovat stav lesních porostů plošně. K tomuto úkolů metodika navrhuje využít data DPZ, která svou podstatou umožňují plošný monitoring zdravotní stav lesa bez nutnosti kontroly na místě. S využitím této informace nebude nutné konat lesní obchůzky v bezproblémových částech lesa a naopak to umožní zaměřit dostupné personální kapacity na problematická území, ze kterých by se mohlo docházet k rozšíření do okolních porostů.

Metodika ve svém základu navrhuje využití dvou zdrojů dat DPZ a to satelitní data Sentinel-2 a hyperspektrální letecká data. Satelitní data Sentinel-2 mají charakter bezplatně přístupných dat a jejich úlohou je upozornit uživatele na nejnápadnější změny (začínající disturbance) v lesních porostech. Díky své snímací frekvenci jednoho snímání za 5 dní mají potenciál poskytovat uživateli plošnou informaci o aktuálním stavu. Z důvodu jejich hrubého spektrálního (počet spektrálních pásem) a prostorového rozlišení (20 x 20 m na pixel) potom navrhujeme využít HS letecká data, která vyplňují nedostatky v prostorovém a spektrálním rozlišení, čímž umožní s větší přesností identifikovat místa začínajícího rozpadu porostů. Nedílnou součástí pořízení leteckých HS dat je i pořízení aktuální informace o výšce povrchu lidarem. Informace o výšce objektů je využitelná pro satelitní i hyperspektrální letecká data, kde umožní odfiltrovat pozadovou informaci z přízemní vegetace v lesní porostech i mimo ně.

Z analýzy leteckých HS dat se ukázalo, že jejich použití v topograficky členitém terénu je poněkud omezené, protože náročné geometrické a atmosférické korekce vnášejí do dat chyby, které se pak následně propály do odhadů biochemických indikátorů listoví. I když HS letecká data (v analýze použita data v rozlišení 5 m na pixel) poskytují detailnější pohled na stav porostů, každopádně vzhledem k velikosti korun převažujících smrkových porostů neumožňuje monitorovat situaci na úrovni jednotlivých stromů, ale je spíše využitelná na úrovni menších skupin stromů. Satelitní data Sentinel-2 jsou mnohem robustnější co se týče jejich předzpracování. Nezbytná je filtrace snímků s oblačností, proto jsme přistoupili k výpočtu DI z bezoblačných ročních kompozitů. Výpočet sklonu trendu DI v krátkodobém časovém horizontu (několik let) poměrně dobře identifikuje poškozené porosty většího rozsahu než 40 x 40 m, avšak nerozlišuje zda poškození vzniklo přirozeným odumíráním např. po napadením kůrovcem, či zda se jednalo o řízenou těžbu. Z tohoto důvodu, se kombinace satelitních dat s leteckými jevila jako nejvhodnější. Detekce ohnisek poškození byla provedena jak z dat Sentinel-2, tak z leteckých hyperspektrálních. Výhodou leteckých dat bylo i využití digitálního modelu povrchu, který byl odvozen ze souběžně pořízených lidarových dat. A právě kombinací lidarů a HS dat šlo velmi dobře eliminovat detekované těžby, které analýza DI ze satelitních dat nesprávně označila jako ohniska poškození. Pro vytyčení potenciálně ohrožených porostů jsme zvolili přístup geometrického šíření poškození, pomocí obalových zón ve vzdálenosti 25 m, 50 m a 100 m od kraje ohnisek disturbance detekovaných z DI. Uživatel pak v terénu může operovat s ohnisky a obalovými zónami určených z DI, poškozenými skupinami stromů detekovaných z HS dat a barevnou syntézou vegetačních indexů, které mu umožní přesnější zacílení a lepší navigaci v terénu při pozemním šetření odumírajících stromů.

7. Seznam zkratk

ATCOR-4 Software pro atmosférické korekce leteckých dat

Cab Obsah chlorofylu a+b v listoví

CASI	Letecký obrazový spektrometr operující ve viditelné a blízké infračervené části spektra
Cw	Obsah vody v listoví
CRI	Spektrální index, z angl. Carotenoid Reflectance Index
ČÚZK	Český úřad zeměměřický a katastrální
DI	Spektrální index, z angl. Disturbance Index
DPZ	Dálkový průzkum Země
ENVI	Software pro analýzu dat dálkového průzkumu
ESA	Evropská kosmická agentura, z angl. European Space Agency
EVI	Spektrální index, z angl. Enhanced Vegetation Index
FLIS	Letecká laboratoř, z angl. Flying Laboratory of Imaging Systems
GNSS	Globální navigační satelitní systém
HLS	Harmonizovaný Landsat a Sentinel-2 produkt
HS	Hyperspektrální
KRNAP	Krkonošský národní park
LAI	Index listové plochy, z angl. Leaf Area Index
LMA	Obsah sušiny vztažený k ploše listu, z angl. Leaf Mass per Area
MSI	Spektrální index, z angl. Moisture Stress Index
NASA	Národní úřad pro letectví a vesmír USA, z angl. Aeronautics and Space Administration
NIR	Blízké infračervené pásmo, z angl. Near Infrared
SASI	Letecký obrazový spektrometr operující krátkovlnné infračervené části spektra
SWIR	Krátkovlnné infračervené pásmo, z angl. Short Wave Infrared

ZCHÚ Zvláště chráněné území

UAV Bezpilotní letoun / dron, z angl. Unmanned Aerial Vehicle

8. Citovaná literatura

- Abdullah, H., Skidmore, A.K., Darvishzadeh, R., Heurich, M., 2019. Sentinel-2 accurately maps green-attack stage of European spruce bark beetle (*Ips typographus*, L.) compared with Landsat-8. *Remote Sensing in Ecology and Conservation* 5, 87–106. <https://doi.org/10.1002/rse2.93>
- Bárta, V., Lukeš, P., Homolová, L., 2021. Early detection of bark beetle infestation in Norway spruce forests of Central Europe using Sentinel-2. *International Journal of Applied Earth Observation and Geoinformation* 100, 102335. <https://doi.org/10.1016/j.jag.2021.102335>
- Blickensdorfer, L., Oehmichen, K., Pflugmacher, D., Kleinschmit, B., Hostert, P., 2024. National tree species mapping using Sentinel-1/2 time series and German National Forest Inventory data. *Remote Sensing of Environment* 304, 114069. <https://doi.org/10.1016/j.rse.2024.114069>
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., Grégoire, J.M., 2001. Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment* 77, 22–33.
- Claverie, M., Ju, J., Masek, J.G., Dungan, J.L., Vermote, E.F., Roger, J.-C., Skakun, S.V., Justice, C., 2018. The Harmonized Landsat and Sentinel-2 surface reflectance data set. *Remote Sensing of Environment* 219, 145–161. <https://doi.org/10.1016/j.rse.2018.09.002>
- Cohen, W.B., Goward, S.N., 2004. Landsat's role in ecological applications of remote sensing. *BioScience* 54, 535–545.
- Delegido, J., Verrelst, J., Alonso, L., Moreno, J., 2011. Evaluation of Sentinel-2 Red-Edge Bands for Empirical Estimation of Green LAI and Chlorophyll Content. *Sensors* 11, 7063–7081. <https://doi.org/10.3390/s110707063>
- Gitelson, A.A., 2002. Assessing carotenoid content in plant leaves with reflectance spectroscopy. *Photochemistry and Photobiology* 75, 272–281.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment, Big Remotely Sensed Data: tools, applications and experiences* 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hais, M., Jonášová, M., Langhammer, J., Kučera, T., 2009. Comparison of two types of forest disturbance using multitemporal Landsat TM/ETM+ imagery and field vegetation data. *Remote Sensing of Environment* 113, 835–845. <https://doi.org/10.1016/j.rse.2008.12.012>
- Hais, M., Wild, J., Berec, L., Brůna, J., Kennedy, R., Braaten, J., Brož, Z., 2016. Landsat Imagery Spectral Trajectories—Important Variables for Spatially Predicting the Risks of Bark Beetle Disturbance. *Remote Sensing* 8, 687. <https://doi.org/10.3390/rs8080687>
- Hansen, M.C., Loveland, T.R., 2012. A review of large area monitoring of land cover change using Landsat data. *Remote Sensing of Environment, Landsat Legacy Special Issue* 122, 66–74. <https://doi.org/10.1016/j.rse.2011.08.024>
- Hansen, M.C., Potapov, P.V., Moore, R., Hancher, M., Turubanova, S.A., Tyukavina, A., Thau, D., Stehman, S.V., Goetz, S.J., Loveland, T.R., Kommareddy, A., Egorov, A., Chini, L., Justice, C.O.,

- Townshend, J.R.G., 2013. High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science* 342, 850–853. <https://doi.org/10.1126/science.1244693>
- Hanuš, J., Slezák, L., Fabiánek, T., Fajmon, L., Hanousek, T., Janoutová, R., Kopkáně, D., Novotný, J., Pavelka, K., Píkl, M., Zemek, F., Homolová, L., 2023. Flying Laboratory of Imaging Systems: Fusion of Airborne Hyperspectral and Laser Scanning for Ecosystem Research. *Remote Sensing* 15, 3130. <https://doi.org/10.3390/rs15123130>
- Healey, S.P., Cohen, W.B., Zhiqiang, Y., Krankina, O.N., 2005. Comparison of Tasseled Cap-based Landsat data structures for use in forest disturbance detection. *Remote Sensing of Environment* 97, 301–310. <https://doi.org/10.1016/j.rse.2005.05.009>
- Homolová, L., Lukeš, P., Malenovský, Z., Lhotáková, Z., Kaplan, V., Hanuš, J., 2013. Measurement methods and variability assessment of the Norway spruce total leaf area: Implications for remote sensing. *Trees - Structure and Function* 27, 111–121.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., Ferreira, L.G., 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment* 83, 195–213.
- König, S., Thonfeld, F., Förster, M., Dubovyk, O., Heurich, M., 2023. Assessing Combinations of Landsat, Sentinel-2 and Sentinel-1 Time series for Detecting Bark Beetle Infestations. *GIScience & Remote Sensing*.
- Kupková, L., Potůčková, M., Lhotáková, Z., Albrechtová, J., 2018. Forest cover and disturbance changes, and their driving forces: A case study in the Ore Mountains, Czechia, heavily affected by anthropogenic acidic pollution in the second half of the 20th century. *Environ. Res. Lett.* 13, 095008. <https://doi.org/10.1088/1748-9326/aadd2c>
- Lukeš, P., Strejček, R., Křístek, Š., Mlčoušek, M., 2018. Hodnocení zdravotního stavu lesních porostů v České republice pomocí satelitních dat Sentinel-2 (Metodika). Ústav pro hospodářskou úpravu lesů Brandýs nad Labem, specializované pracoviště DPZ, Frýdek-Místek.
- Masek, J.G., Wulder, M.A., Markham, B., McCorkel, J., Crawford, C.J., Storey, J., Jenstrom, D.T., 2020. Landsat 9: Empowering open science and applications through continuity. *Remote Sensing of Environment* 248, 111968. <https://doi.org/10.1016/j.rse.2020.111968>
- MZe, 2023. Zpráva o stavu lesa a lesního hospodářství 2022 (No. 978-80-7434-703– 0). Ministerstvo zemědělství, Praha.
- Porra, R.J., Thompson, W.A., Kriedemann, P.E., 1989. Determination of accurate extinction coefficients and simultaneous equations for assaying chlorophylls a and b extracted with four different solvents: verification of the concentration of chlorophyll standards by atomic absorption spectroscopy. *Biochimica and Biophysica Acta* 975, 384–394.
- Senf, C., Pflugmacher, D., Hostert, P., Seidl, R., 2017. Using Landsat time series for characterizing forest disturbance dynamics in the coupled human and natural systems of Central Europe. *ISPRS Journal of Photogrammetry and Remote Sensing* 130, 453–463. <https://doi.org/10.1016/j.isprsjprs.2017.07.004>
- Švik, M., Lukeš, P., Lhotáková, Z., Neuwirthová, E., Albrechtová, J., Campbell, P.E., Homolová, L., 2023. Retrieving plant functional traits through time series analysis of satellite observations using machine learning methods. *International Journal of Remote Sensing* 44, 3083–3105. <https://doi.org/10.1080/01431161.2023.2216847>
- Wellburn, A.R., 1994. The spectral determination of chlorophyll a and chlorophyll b, as well as total carotenoids, using various solvents with spectrophotometers of different resolution. *Journal of Plant Physiology* 144, 307–313.