

Česká zemědělská univerzita v Praze

Fakulta životního prostředí

Katedra prostorových věd



**Detekce napadených stromů lýkožroutem pomocí bezpilotních leteckých
prostředků v okolí NPR Rejvíz**

Bakalářská práce

Vedoucí práce: Ing. Tomáš Klouček, Ph.D.

Bakalant: Stanislav Herber

2021

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Stanislav Herber

Geografické informační systémy a dálkový průzkum Země v životním prostředí

Název práce

Detekce napadených stromů lýkožroutem pomocí bezpilotních leteckých prostředků v okolí NPR Rejvíz

Název anglicky

Detection of infested trees by bark beetle using unmanned aerial vehicles in NPR Rejvíz

Cíle práce

Cílem bakalářské práce je prokázat využitelnost bezpilotních leteckých prostředků (UAV) v problematice detekce napadených stromů lýkožroutem, a to na základě analýzy časové řady RGB, multispektrálních a termálních UAV snímků pořízených v roce 2019 v okolí NPR Rejvíz. Hlavním cílem práce je prokázání možného přínosu termálních snímků při detekci lesních disturbance způsobených aktivitou lýkožrouta, a to zejména při odlišení zdravých, nově napadených a suchých stromů.

Jednotlivé cíle bakalářské práce souvisí s těmito výzkumnými otázkami:

- 1) Jsou RGB data pořízená z UAV využitelná pro detekci lesní disturbance způsobené primárně kůrovcovou aktivitou?
- 2) Jsou termální data pořízená pomocí UAV využitelná pro detekci lesní disturbance zapříčiněné primárně kůrovcovou aktivitou?
- 3) Jsou patrné spektrální rozdíly mezi zdravými, napadenými a suchými stromy?
- 4) Vykazují lesní porosty v době před napadením kůrovcem vyšší teplotu?

Metodika

Metodiku bakalářské práce lze rámcově rozdělit na:

- 1) Předzpracování vstupních dat (například přesná georeference snímků apod.)
- 2) Kombinace vstupních dat (RGB+termální snímek, multispektrální+termální snímek)
- 3) Tvorba referenčních dat (trénovací vs. validační)
- 4) Klasifikace zdravých, napadených a mrtvých stromů dle vhodně zvoleného algoritmu
- 5) Vyhodnocení přesnosti klasifikace s důrazem na zhodnocení přínosu termálních dat
- 6) Zodpovězení výše uvedených výzkumných otázek.

Doporučený rozsah práce

30 – 50 stran

Klíčová slova

UAV; vegetační indexy; teplota povrchu; lesní disturbance; lýkožrout smrkový

Doporučené zdroje informací

- Abdullah, H., Darvishzadeh, R., Skidmore, A.K., Groen, T.A., Heurich, M., 2018. European spruce bark beetle (*Ips typographus*, L.) green attack affects foliar reflectance and biochemical properties. *Int. J. Appl. Earth Obs. Geoinf.* 64, 199–209. <https://doi.org/10.1016/j.jag.2017.09.009>
- Abdullah, H., Darvishzadeh, R., Skidmore, A.K., Heurich, M., 2019. Sensitivity of Landsat-8 OLI and TIRS Data to Foliar Properties of Early Stage Bark Beetle (*Ips typographus*, L.) Infestation. *Remote Sens.* 11, 1–23. <https://doi.org/10.3390/rs11040398>
- Hais, M., Wild, J., Běrec, L., Brúna, J., Kennedy, R., Braaten, J., Brož, Z., 2016. Landsat imagery spectral trajectories-important variables for spatially predicting the risks of bark beetle disturbance. *Remote Sens.* 8. <https://doi.org/10.3390/rs8080687>
- Havašová, M., Bucha, T., Ferenčík, J., Jakuš, R., 2015. Applicability of a vegetation indices-based method to map bark beetle outbreaks in the High Tatra Mountains. *Ann. For. Res.* 58, 295–310. <https://doi.org/10.15287/afr.2015.388>
- Klouček, T., Komárek, J., Surový, P., Hrach, K., Janata, P., Vašíček, B., 2019. The Use of UAV Mounted Sensors for Precise Detection of Bark Beetle Infestation. *Remote Sens.* 11, 1561. <https://doi.org/10.3390/rs11131561>
- Näsi, R., Honkavaara, E., Lyytikäinen-Saarenmaa, P., Blomqvist, M., Litkey, P., Hakala, T., Viljanen, N., Kantola, T., Tanhuanpää, T., Holopainen, M., 2015. Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level. *Remote Sens.* 7, 15467–15493. <https://doi.org/10.3390/rs71115467>

Předběžný termín obhajoby

2020/21 LS – FŽP

Vedoucí práce

Ing. Tomáš Klouček, Ph.D.

Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 12. 3. 2021

doc. Ing. Petra Šímová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 15. 3. 2021

prof. RNDr. Vladimír Bejček, CSc.

Děkan

V Praze dne 30. 03. 2021

Prohlášení

Prohlašuji, že jsem bakalářskou/závěrečnou práci na téma: Detekce napadených stromů lýkožroutem pomocí bezpilotních leteckých prostředků v okolí NPR Rejvíz vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil, které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

Jsem si vědom, že na moji bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů, ve znění pozdějších předpisů, především ustanovení § 35 odst. 3 tohoto zákona, tj. o užití tohoto díla.

Jsem si vědom, že odevzdáním bakalářské práce souhlasím s jejím zveřejněním podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby.

Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

.....

V Horoměřicích dne 31. března 2021

Poděkování

Rád bych touto cestou poděkoval svému vedoucímu práce Ing. Tomáši Kloučkovi, Ph.D. za odborné vedení, rady a asistenci během psaní méj bakalářské práce.

Detekce napadených stromů lýkožroutem pomocí bezpilotních leteckých prostředků v okolí NPR Rejvív

Abstrakt

V posledních letech se kůrovcové kalamity objevují, čím dal častěji. Lýkožrout smrkový (*Ips typographus*) tak představuje pro les vážný ekologický i ekonomický problém. Oslabené stromy, které jsou lákavé pro množení lýkožrouta, se nemohou dostatečně bránit a následkem kůrovcových aktivit umírají. Ke snížení škod je nutné rychle detekovat napadené stromy a provést preventivní ochranu. Výzkum proběhl v oblasti národní přírodní rezervace Rejvív, na pomezí rezervace a hospodářského lesa. V této oblasti je šíření kůrovce pomalejší, což umožňuje dobré podmínky pro detekci napadených stromů. Bakalářská práce se zabývá výzkumem detekce napadených stromů lýkožroutem smrkovým pomocí bezpilotních leteckých prostředků. Cílem práce je prokázat využitelnost RGB, multispektrálních a termálních dat a jejich kombinací k detekci jednotlivých stádií napadených stromů. Na vstupních datech byla nejprve provedena georeference. Dále byly vytvořeny vlastní trénovací a validační data. Následně byla provedena klasifikace jednotlivých stromů pomocí algoritmu Random Forest v software SNAP do kategorií mrtvý, zdravý a napadený strom. Výsledky závěrečné práce prokazují využitelnost UAV dat k detekci jednotlivých fází napadených stromů. Přesnost detekce napadených stromů z RGB dat byla v rozmezí 61-93 % v závislosti na době pořízení snímků. V červenci dosáhl RGB senzor přesnost 61 %. Při použití multispektrálního snímku k detekci napadených stromů byla docílena přesnost 80 %. Při kombinaci termálního a RGB snímku se přesnost detekce napadených stromů zvýšila na 96 %.

Klíčová slova: UAV, vegetační indexy, teplota povrchu, lesní disturbance, klasifikace

Detection of infested trees by bark beetle using unmanned aerial vehicles in NPR Rejvíz

Abstract

In recent years, bark beetle calamities appear, the more often he gave. The spruce lichen-eater (*Ips typographus*) thus represents a serious ecological and economic problem for the forest. Weakened trees, which are attractive for the reproduction of the lichen-eater, cannot be sufficiently defended and die as a result of bark beetle activities. To reduce damage, it is necessary to quickly detect infested trees and provide preventive protection. The research took place in the area of the Rejvíz National Nature Reserve, on the border of the reserve and the commercial forest. In this area, the spread of bark beetles is slower, which allows good conditions for the detection of infested trees. The bachelor's thesis deals with the research of detection of infested trees by spruce lichen-eater using unmanned aerial vehicles. The aim of this work is to demonstrate the usability of RGB, multispectral and thermal data and their combinations to detect individual stages of infested trees. Georeferencing was first performed on the input data. Furthermore, own training and validation data were created. Subsequently, the individual trees were classified using the Random Forest algorithm in the SNAP software into the categories of dead, healthy and infested tree. The results of the final work demonstrate the usability of UAV data to detect individual phases of infested trees. The accuracy of detection of infested trees from RGB data was in the range of 61-93 % depending on the time of image acquisition. In July, the RGB sensor reached an accuracy of 61 %. When using a multispectral image to detect infested trees, an accuracy of 80 % was achieved. The combination of thermal and RGB imaging increased the detection accuracy of infested trees to 96 %.

Keywords: UAV, vegetation indices, surface temperature, forest disturbance, classification

Obsah

1	Úvod	1
2	Cíle práce	3
3	Literární rešerše	4
3.1	Podstata DPZ	4
3.2	Bezpilotní letecké prostředky	4
3.2.1	Podstata bezpilotních leteckých prostředků	4
3.2.2	Historie bezpilotních leteckých prostředků	5
3.2.3	Kategorizace bezpilotních leteckých prostředků	6
3.2.4	Použité bezpilotní letecké prostředky během výzkumu	7
3.2.5	Další příklady bezpilotních leteckých prostředků	8
3.3	Spektrální pásma	9
3.3.1	Spektrální pásma pořízených dat k výzkumu	10
3.4	Miniaturizované UAV senzory	11
3.4.1	Multispektrální senzory	11
3.4.2	RGB senzory	12
3.4.3	Termální senzory	12
3.4.4	Hyperspektrální senzory	13
3.5	Fyzikální podstata monitoringu vegetace	13
3.5.1	Spektrální vlastnosti listu	13
3.6	Klasifikace obrazu	14
3.6.1	Pixelový přístup	14
3.6.2	Objektový přístup	17
3.7	Lýkožrout smrkový	17
3.7.1	Taxonomie	17
3.7.2	Výskyt	17
3.7.3	Potrava	18
3.7.4	Reprodukční cyklus	18
3.7.5	Poškození lesa	18
3.7.6	Přirození nepřátelé	18
3.7.7	Prevence	19

3.8	Práce dalších autorů a jejich napojení na moji práci	19
4	Charakterizace zájmového území.....	23
4.1	Rozšíření kůrovce v NPR Rejvíc.....	23
5	Metodika.....	26
5.1	Vstupní data	26
5.1.1	Použité senzory během výzkumu	27
5.2	Pre-processing vstupních dat	29
5.2.1	Tvorba modelů dat.....	31
5.2.2	Tvorba Canopy Height Modelu	31
5.2.3	Tvorba referenčních dat	32
5.2.4	Klasifikace RGB snímků	33
5.2.5	Klasifikace zdravých, napadených a mrtvých stromů	34
5.2.6	Vyhodnocení přesnosti.....	38
6	Výsledky.....	40
7	Diskuse	45
8	Závěr.....	49
9	Přílohy	50
10	Seznam zkratk.....	52
11	Zdroje.....	53

1 Úvod

V posledních několika letech se rozšíření kůrovce v českých lesích stává velkým a téměř nekontrolovatelným problémem. Není to ale problém týkající se pouze českých lesů. Napadá oslabené lesy napříč kontinenty.

Po Evropě je velmi široce rozšířen vyjma Velké Británie. U nás se vyskytuje téměř všude, kde jsou smrkové porosty. V českých lesích je nejrozšířenější druh lýkožrout smrkový (*Ips typographus*). Když se přemnoží, což dnes vidíme často, je schopen způsobit obrovské škody. Lýkožrout smrkový je tmavě hnědý až téměř černý lesklý brouk. Je 4,5 mm dlouhý s typicky uspořádanými zoubky, odstálými zlatavými chloupky a useknutou zádí krovek. Pro kůrovce je nejvíce lákavou dřevinou smrk ztepilý, který se vyskytuje převážně po celé severní polokouli. Původně se nacházel ve vysokých polohách Evropy s přesahem do Asie (Lýkožrout Smrkový | Kůrovcové Info, 2016).

Kůrovec byl původně druhem horským, který se postupem času rozšířil i do smrkových monokultur v nižších polohách. Jeho význam je spojen především s pěstováním smrkových hospodářských monokultur. Nejčastěji se jedná o smrk ztepilý. Lýkožrout smrkový původně nebyl tak široce rozšířen. Například oblast Křivoklátska byla ještě během začátku 20. století bez jeho přítomnosti (Kula, 2014).

V posledních letech intenzita kůrovcových kalamit velmi stoupá. Objem smrkového a borového napadeného dříví se za posledních 40 let zvýšil o téměř 700 %. Z části za to může nárůst stromových monokultur zmíněných výše. Celkově byly změny ve struktuře lesů zodpovědné za 50 % pozorovaných nárůstů kůrovcových disturbancí. Za druhou polovinu může změna klimatu (Krokene & Liebhold, 2020).

Existuje celá řada příčin tohoto nepříznivého stavu. Mezi ty hlavní patří dlouhodobý nedostatek půdní vláhy a extrémní teploty. Další příčinou je nepružnost současného systému provádění prací v lese, obecný nedostatek pracovních sil v lesnictví, a také nevhodné nastavení opatření v ochraně lesa (Trgala & Modliger, 2019).

Kůrovec ovlivňuje nejenom stromy a dřevo jako takové, ale má i dopad na vodní cyklus, živinový cyklus a cyklus fixace uhlíku. Lýkožrout smrkový se vyskytuje ve smrkových porostech, které jsou starší 60 let. Napadá silnější část kmene stromů. Nejslabší části přenechává jiným druhům kůrovců. Například Lýkožrout smrkový je sekundárním škůdcem. Napadá čerstvě odumřelé stromy nebo stromy pod velkým stresem. Pokud dojde k jeho přemnožení a už nemá dostatek potravy, pak napadá i zdravé stromy. Zdravé stromy poté odumírají. To představuje velký ekologický problém (Krokene & Liebhold, 2020).

Podle predikcí by mělo v Evropě dojít k nárůstu objemu napadeného dřeva v letech 2021-2030 na 17,9 mil. m³ ročně. Z toho lze usuzovat, že moderní lesy budou mít

větší úroveň poškození, než lesy za posledních 40 let. V dalších letech se počítá s nárůstem kůrovcových kalamit v celém mírném pásu Evropy. Jak jsem již uvedl, výrazným faktorem zvyšování kůrovcových kalamit jsou změny klimatu, zejména neustálé zvyšování průměrné teploty ovzduší. Tato změna má výrazný vliv nejenom na samotného kůrovce, na jeho přežití a vývoj i v oblastech s vyšší nadmořskou výškou, ale i na stav jednotlivých stromů. Samotné stromy jsou vlivem tepla oslabené a snáze napadnutelné kůrovcem (Krokene & Liebhold, 2020).

Pro značné snížení jak ekologických, tak ekonomických ztrát na lesních porostech je nutná včasná detekce stromů napadených kůrovcem, které může sloužit jako podklad pro pohotovou reakci. Proto je nutné mít způsob, kterým lze dosáhnout rychlých a přesných výsledků o právě zmíněném výskytu lýkožrouta smrkového.

Jednou z tradičních metod je pozemní terénní průzkum. Nicméně tato metoda je finančně náročná a komplikovaná zejména v případě velkých a špatně přístupných lesních porostů. Jako ekonomicky přijatelná alternativa se proto nabízí použití bezpilotních leteckých prostředků osazených různými miniaturizovanými kamerami (od levných RGB kamer až po profesionální multispektrální a termální kamery), které mohou nabízet efektivní a zároveň cenově dostupný nástroj pro monitoring rozšíření kůrovce nejenom v českých lesích.

Domnívám se, že použití bezpilotních prostředků osazených multispektrální, případně termální kamerou, by mohlo být dobrým způsobem jak efektivně a zároveň „levně“ detekovat rozšíření kůrovce v nejenom v českých lesích. Tímto způsobem, by se mohlo předejít velkému množství škod a byla by zajištěna dlouhodobá prosperita lesa.

2 Cíle práce

Cílem bakalářské práce je prokázat využitelnost bezpilotních leteckých prostředků v problematice detekce napadených stromů lýkožroutem, na základě časové řady RGB, multispektrálních a termálních snímků. Důraz bude kladen zejména na přínos termálních dat při detekci lesních disturbancí, způsobených aktivitou lýkožrouta smrkového. Mimo jednotlivých senzorů a na jejich základě pořízených snímků budou na příkladu řízené klasifikace využívající algoritmus Random Forest statisticky porovnány i různé datové modely vzniklé jejich vzájemnou kombinací.

Jednotlivé cíle bakalářské práce souvisí s těmito výzkumnými otázkami:

- 1) Jsou RGB data pořízená z bezpilotních prostředků využitelná pro detekci lesní disturbance, způsobenou primárně kůrovcovou aktivitou?
- 2) Jsou termální data pořízená z bezpilotních prostředků využitelná pro detekci lesní disturbance, způsobenou primárně kůrovcovou aktivitou?
- 3) Jsou patrné rozdíly mezi zdravými, napadenými a mrtvými stromy?
- 4) Vykazují lesní porosty v době před napadením kůrovcem vyšší teplotu?

3 Literární rešerše

V dnešní době se významné množství autorů zabývá tematikou detekce napadených stromů kůrovcem za pomoci bezpilotních prostředků. Pro porovnání jsem vybral několik prací týkajících se právě tímto tématem a shrnul jsem jaká data ke svému výzkumu využívali (viz Tabulka 1). Z průzkumu vyplývá, že se často používají RGB a rededge data, na druhou stranu není velmi běžné použití termálního pásma.

3.1 Podstata DPZ

Dálkový průzkum je proces detekce a monitorování fyzikálních charakteristik objektů měřením odraženého a emitovaného záření. Typicky toto měření je prováděno ze satelitů, letadel nebo bezpilotních systémů. Z výsledných dat jsme schopni určit kompozici povrchu Země a atmosféry. Snímání může být prováděno v různých prostorových měřících, od lokálních až po globální snímky. Z pohledu způsobu pořizování dat se DPZ rozděluje na aktivní a pasivní snímání (Read & Torrado, 2009).

3.2 Bepilotní letecké prostředky

Bepilotní letecké prostředky jsou letadla bez lidského operátora na palubě. Běžně se označují jako „drony“. Bepilotní systémy jsou řízeny, buď na dálku, nebo automaticky pomocí programu. Na rozdíl od konvenčních letadel lze UAV pilotovat na určité úrovni autonomie (Markus, 2014). Nicméně evropská legislativa říká, že je v Evropské Unii dovoleno pilotovat bepilotní systém pouze za přímého dohledu pilota nebo pozorovatele, a to bez jakýchkoliv vizuálních pomůcek. Pilot a pozorovatel nesmí ztratit dron ze svého dohledu. Jedná se o systém, který se skládá z bepilotního letadla a řídicí stanice (EU, 2019). V současné době se nacházíme v období velkých změn v oblasti pravidel regulující provoz bepilotních prostředků. Co se legislativy týče, tak se právě ocitáme v přechodném období mezi postupným odstupem od předešlého užívání Doplnku X jakožto hlavní obsah pravidel pro užívání bepilotních systémů a následným přechodem na legislativu, která je kontrolována Evropskou unií. Nyní je nutnost provozovatele bepilotního systému být registrován. Člověk se registruje pouze jednou, bez ohledu na to, kolik vlastní bepilotních systémů. Provozovatel obdrží registrační číslo, které se musí objevit na každém z vlastněných dronů. Dále se ruší kategorie hmotnostních limitů. (Úřad pro Civilní Letectví, 2020)

3.2.1 Podstata bepilotních leteckých prostředků

Bepilotní systémy se dělí na dva hlavní typy: lehčí a těžší tělesa než vzduch. Systémy, které jsou lehčí než vzduch, využívají k pohybu plyny s rozdílnou hustotou a teplotou

než vzduch. Jejich pohyb je závislý čistě na okolním prostředí. Například se může jednat o horkovzdušný balon. U takových prostředků je aplikován Archimedův zákon. První Archimedův zákon říká, že každé těleso setrvává v klidu nebo v rovnoměrném přímočarém pohybu, pokud není nuceno vnějšími silami tento stav změnit (Britannica, 2020). Dále se vyskytují bezpilotní prostředky, které jsou častokrát mnohonásobně těžší než vzduch. Takové systémy musí překonat odpor a zemskou gravitaci. Zde je aplikován Newtonův třetí zákon. Tento zákon říká, že konkrétně v oblasti leteckých prostředků, vztlak na spodní části křidel vzniká díky silové reakci při ohybu svazku proudnic vzduchu. Na pohybující se křídlo působí síla směrem vzhůru (Newton's Laws of Motion, 2021). V průběhu času došlo k rapidnímu vývoji bezpilotních prostředků.

3.2.2 Historie bezpilotních leteckých prostředků

Historie UAV sahá až do poloviny 19. století, kdy v roce 1858 Gaspard Félix Tournachon, také známý pod pseudonymem Nadar, pořídil první leteckou fotografii z horkovzdušného balonu (Consortiq, n.d.). Během první světové války došlo k vývoji letecké fotografie, s čímž byl také spojen vývoj bezpilotních prostředků jako takových. V roce 1915 v bitvě u Neuve Chapelle byly využity letecké fotografie k detekci pozic nepřátelských vojsk (Air & Space Magazine, 2018).

V roce 1917 bylo představeno první UAV torpédo s názvem Kettering BUG. Jednalo se o vzdušné torpédo vybavené výbušninou, které po dosažení požadované destinace spadlo na cíl. Svůj cíl dokázalo zasáhnout na vzdálenost 64 km.

Ve 30. letech se drony začaly používat pro výcvikové metody. Britské královské letectvo využívalo UAV s názvem „Queen Bee“ jako létající terče k nácvičce střelby na cíl. Podobný program byl také aplikován v letectvu Spojených států amerických. V 60. letech se začaly používat bezpilotní systémy k průzkumu, mimo jiné se objevily i ve válce ve Vietnamu. Proslavily se drony „Ryan Firebee“ sloužící jako průzkumná zařízení. (Ryan Firebee BQM-34A „Drone“, 2008)

V roce 1973 byl v Izraeli postaven první UAV s přenášením obrazu v reálném čase. Jmenoval se „Tadiran Mastiff“. V roce 1986 byl sestaven UAV „Pioneer“. Jednalo se o jeden z prvních bezpilotních prostředků námořnictva. Vznikl ve spolupráci USA a Izraele. V roce 1994 Američané provedli přestavbu UAV „NAT750“, čímž vzniká 1. generace UAV „Predator“, která byla využita zejména ve válce v Afghánistánu. Na začátku druhého tisíciletí došlo k velkému rozmachu bezpilotních prostředků. Nejznamenatelnější to bylo ve zbrojním průmyslu. Nicméně později pronikly i do civilní a komerční sféry.

V roce 2010 na konferenci spotřební technologie CES v USA byl představen první telefonem ovládaný UAV. Jednalo se o koptéru s názvem „ARDrone“. Koptéra se ovládala plně pomocí telefonu a byla schopná dosáhnout rychlosti 18 km/h (The Guardian, 2010). V roce 2013 firma DJI představila svůj první model quadrokoptéry s názvem „DJI Phantom“. UAV obsahovalo interní GPS systém, což umožnilo spolehlivější a lepší manévrovatelnost (Timeline of DJI Drones, 2018).

V současnosti se řada společností zaměřuje na vývoj malých UAV sloužící pro zábavní, rekreační a komerční účely.

Podle amerického deníku Business Insider je očekáván významný boom v této oblasti. Díky rychlému vývoji bezpilotních systémů bylo nutné jednotlivé stroje od sebe rozdělit. Proto se vytvořily nejrůznější druhy kategorií, dle kterých jsou systémy diferenciovány.

3.2.3 Kategorizace bezpilotních leteckých prostředků

V dnešní době je na trhu obrovské množství UAV sloužících k různým účelům. Jednotlivé drony lze rozdělovat do kategorií například podle:

- hmotnosti
- typu konstrukce
- účelu využití
- náročnosti pilotování
- způsobu ovládání
- velikosti
- ceny

Některé z těchto kategorií budou více přiblíženy dále.

- Mezi první druh rozdělení spadá kategorizace dle typu konstrukce. Stroje se dělí na:
 - UAV s pevnými křídly
 - UAV s rotory

- Dále se bezpilotní systémy rozdělují dle účelu využití na:
 - Průzkumné
 - Bojové
 - Logistické
 - Výzkumné
 - Civilní

- Dalším z třídy rozdělení je kategorizace dle hmotnosti. Toto rozdělení je v praxi následující:
 - $\leq 0,91$ kg
 - $> 0,91$ kg a < 7 kg
 - 7–25 kg
 - > 25 kg

(EU, 2019)

- Dále se bezpilotní systémy mohou rozdělovat i podle způsobu využití na:
 - Rekreačně sportovní
 - Vydělečné
 - Experimentální
 - výzkumné

(EU, 2019)

- V neposlední řadě se bezpilotní systémy dají rozdělit podle cenové kategorie:

Bezpilotní systémy se mohou ve své ceně výrazně lišit. Na trhu se nachází drony do stovek korun, jako například některé RC drony, ale i specifické bezpilotní systémy rostoucí svou cenou.

3.2.4 Použité bezpilotní letecké prostředky během výzkumu

Jedním z využitých UAV během výzkumu byl model eBee Plus (viz Obr. 1). Jedná se o typ UAV fixed-wing, neboli křídlo, od společnosti SenseFly. Jedná se o velmi lehký typ dronu s váhou pouhých 1,1 kg a rozpětím křídel 110 cm (GEOTRONICS, 2016). UAV je přímo postaveno pro použití senzoru SODA, nicméně je možné i přidat senzory Parrot sequioa a ThermoMAP. Maximální doba letu je 59 minut. Za tuto dobu je dron schopný nasnímkovat území až o velikosti 220 ha. Bez pozemních lícovacích bodů je možné dosáhnout absolutní přesnosti až 3 cm (senseFly, 2016).



Obr. 1: Bezpilotní systém eBee Plus (zdroj: <https://geotronics.cz/sensefly-ebec-plus/>)

Dalším z využitých UAV během výzkumu byl model eBee X (viz Obr. 2). Opět se jedná o tzv. fixed-wing typ UAV od společnosti SenseFly. Opět je to lehký systém s hmotností pouze 1,3–1,6 kg. Hmotnost se odvíjí od použité baterie. Rozpětí křídel je 116 cm. UAV je vybaveno širokým spektrem kamer k použití, jako například Parrot Sequoia+, MicaSense RedEdge MX a další (SenseFly, 2018). Maximální letová doba je kolem 90 minut. Odvíjí se od hmotnosti kamery a baterie. Rychlost letu tohoto UAV je v rozmezí 40 až 110 km/h. Jedná se o velmi výkonný bezpilotní prostředek umožňující během svojí letové doby pokrýt až 500 ha oblasti (SenseFly, 2016)



Obrázek 2: Bezpilotní systém eBee X zdroj (<https://www.sensefly.com/drone/ebec-x-fixed-wing-drone>)

3.2.5 Další příklady bezpilotních leteckých prostředků

Existuje velké množství dalších bezpilotních systémů, které jsou na dnešním trhu k dispozici. Jelikož se UAV dostalo v poslední době velké popularity veřejnosti, vznikají neustále nové a nové modely. Výše uvedené typy UAV jsou z produkce společnosti SenseFly, nicméně to není jediná velká společnost vyrábějící bezpilotní

systemy. Mezi další velmi významnou společností v oblasti produkce bezpilotních prostředků lze zařadit také čínskou společnost DJI (Da-Jiang Innovations).

Společnost DJI se pyšní pozicí nejvyšší příčky v oblíbenosti u široké veřejnosti v oblasti komerčních bezpilotních systémů. Její podíl na trhu s UAV pro veřejnost pokrývá až 70 % celkové kapacity (Bloomberg, 2021). Nicméně se společnost DJI nesoustředí pouze na komerční sféru, ale má podíl i na trhu pro vědecké účely. Modely užívané pro modelování přírodních metrik jsou například UAV DJI Agras a dále také DJI Phantom 4.

Nejpopulárnějším modelem firmy DJI, sloužící nejen pro účely detekce a ochrany vegetace je například DJI Phantom 4. Jedná se UAV typu kvadrokoptéra, tedy systém se čtyřmi rotory. Váží 1380 g a maximální dobu letu má kolem 28 minut. DJI Phantom 4 Pro patří mezi nejlepší spotřebitelské UAV s kamerou (DJI, 2016). Tento byl základem modelu DJI Phantom Multispectral, který se soustředí na oblast efektivního zemědělství. Obsahuje 6 spektrálních kamer. V reálném čase je možné sledovat stav plodin a půdy. Dále je i schopný detekovat napadením rostlin škůdci či plevelem. Systém umožňuje zobrazení v reálném čase náhled indexu NDVI (DJI, 2019).

Firma DJI vyrábí i UAV čistě zemědělského využití. Jedním z takových systémů je DJI Agras T16. Jedná se o dron typu koptéra s ochranou proti vodnímu poškození IP67. Je schopen pokrýt oblast až 6000 m² v pouhých 10 minutách. Hlavním způsobem využití je plošné rozprašování pesticidů a hnojiv nad zájmovou oblastí. UAV obsahuje rozprašovače na každém rotoru. DJI Agras T16 váží 18.5 kg s nosností až do celkové hmotnosti 42 kg. Maximální rychlost je až 36 km/h (DJI, 2018).

3.3 Spektrální pásma

Snímání dat pomocí dálkového průzkumu Země probíhá v hodnotách elektromagnetického spektra nejenom v oblasti viditelného spektra. Podle počtu a vlnové délky nasnímaných pásem se liší i využití pořízených dat.

Všechny senzory dálkového průzkumu země mají jistá omezení spektrální citlivosti. To je označováno jako spektrální rozlišení. Žádný senzor není schopný zaznamenávat na všech vlnových délkách elektromagnetického spektra. Jednotlivé nasnímané vlnové délky se označují jako pásma (GIS Geography, 2021).

Spektrální pásmo je tedy část elektromagnetického záření s určitým rozmezím vlnové délky. Počet snímaných pásem se liší podle použitého typu senzoru (Slovník VÚGTK, n.d.).

3.3.1 Spektrální pásma pořízených dat k výzkumu

Vstupní data bakalářské práce jsou výsledkem snímání pomocí bezpilotních systémů v různých částech elektromagnetického spektra. Snímky se na spektru nachází ve viditelné části, ale i mimo tuto oblast. Shrnutí jednotlivých spektrálních pásem (viz Tabulka 2).

Tabulka 2: Souhrn vlnových délek použitých k nasnímání vstupních dat

Rozmezí na elektromagnetickém spektru	Název pásma	Využití vlnové délky v praxi	Senzory snímající v tomto pásmu
400 - 700nm	RGB	Tvorba orthomosaiek	SODA kamera, Canon kamery
690–730 nm	Red-edge	Mapy obsahu chlorofylu	RapidEye sensory, MultiSPEC 4, Red Edge-MX
750–2000 nm	NIR	Monitoring zdravotního stavu vegetace	Tetracam, parrot sequoia

Prvním z druhů způsobů získávání dat je RGB snímání. Jedná se o metodu snímání v červených, zelených a modrých úzkých částech viditelného elektromagnetického spektra. Díky kombinaci těchto pásem je možné snímek zobrazit v přirozených barvách (David Sandwell, 2004)

Dále je možné snímat data i z desítek pásem v optické oblasti elektromagnetického pásma. Takovému snímání se říká multispektrální. Díky tomu je možné pozorovat rozdíly v různých materiálech. Každý materiál odráží a absorbuje různé množství signálu. Například satelit Landsat 8 snímá až v 11 pásmech. Mezi snímaná pásma často patří červené, zelené, modré, blízké infračervené, SWIR 1 a 2 (Malvern Panalytical, 2021).

Specifickým pásmem multispektrálních dat vhodné pro studium vegetace je RedEdge. Toto pásmo se na spektrální křivce nachází v oblasti mezi červeným a blízkým infračerveným pásmem. Pomocí RedEdge pásma je možné získat další informace o vegetaci a jejích charakteristikách. Mezi takové charakteristiky patří například obsah chlorofylu v listech. Dále je možné zjistit celkový zdravotní stav rostliny či typ rostliny. Spektrální pásmo označuje hranici mezi absorpcí chlorofylu v červené oblasti viditelného spektra díky struktuře listů v oblasti NIR pásma. RedEdge pásmo se nachází v rozmezí 690 až 730 nm (The RapidEye, 2012).

Výše zmíněné infračervené pásmo je způsob získávání dat z oblasti elektromagnetického spektra, konkrétně mezi oblastí viditelného a mikrovlnného spektra. Jedná se o jednu ze tří částí termálního spektra. Near-Infrared (NIR) se nachází v oblasti 8-12 μm za hranicí viditelného spektra. Další jsou Mid-Infrared a Far-Infrared. Při termálním snímání je měřena emitovaná radiace z povrchu. Každé přirozené těleso odrazuje i vyzařuje nějaké množství záření. V tepelné části spektra je vyzařovaná hodnota v důsledku tepelného stavu mnohem intenzivnější než sluneční odražené záření, proto senzory, které operují v této oblasti spektra detekují primárně tepelné radiční vlastnosti těles, Země (Künzer & Kuenzer, 2012). Rozptýl signálu je v tomto pásmu zanedbatelný, díky délce vlnových délek. Toto snímání je méně pohlcováno a rozptýlováno atmosférou, čímž vznikají velmi ostré snímky s dobrým kontrastem. Voda se na těchto snímcích zobrazuje úplně černá (Prakash, 2000).

Mezi další typ snímání, které již není součástí vstupních dat mého výzkumu, je hyperspektrální snímání. Hyperspektrální snímání je způsob získávání obrazů z více než stovky souvislých spektrálních pásem pro stejnou prostorovou oblast. To umožňuje identifikaci a charakterizaci materiálů v krajině. Oproti multispektrálnímu snímání má výhodu v tom, že je schopné detekovat molekulární absorpci. Častým polem využití těchto dat, je určování obsahu vody v listech nebo celulózy v zemědělství. Dále se data využívají například v geologii k detekci minerálů a typů zeminy (USGS ghisat, 2014).

3.4 Miniaturizované UAV senzory

Bezpilotní systémy jsou schopny díky kombinaci velkého prostorového rozlišení a rychlého a přesného manévrování částečně schopny nahradit satelitní i letecké snímání (Suárez et al., 2008). Díky častějšímu použití bezpilotních systémů dochází také k procesu miniaturizace nejrůznějších senzorů (Hentati & Fourati, 2020). Proto je možné k dronu připojit více užitečných senzorů než dříve. Jednotlivé senzory snímají v rozdílných pásmech, čímž se diferencují ve způsobu využití. Jednou z podmínek korektního využití takových dat, je nutné na získaných datech provést radiometrickou a geometrickou kalibraci (Suárez et al., 2008). Multispektrální senzory patří v dnešní době mezi velmi často užívané nástroje při snímání bezpilotními prostředky.

3.4.1 Multispektrální senzory

Jak již bylo zmíněno v současnosti se při výzkumech využívají čím dál více multispektrální senzory. Tyto senzory snímají i v oblastech mimo viditelného spektra. Multispektrální senzory jsou založené na myšlence snímání v několika pásmech vlnového spektra. Mezi taková pásma lze zařadit například červené, zelené, modré,

blízké infračervené a red-edge pásma. Každý povrch má rozdílnou odrazivost a absorpci. Díky tomu je možné pozorovat rozdíly v materiálech. Z nasnímaných dat lze vypočítat nejrůznější spektrální indexy, které nám poskytnou důležité informace o vlastnostech rostlin. Mezi vegetační indexy spadají například NDVI, LAI nebo NDWI. Velmi často se multispektrální snímky aplikují v oblasti zemědělství a lesnictví. Dále se používá v geologii k detekci minerálů. (Jensen J.R., 2015). Před použitím multispektrálních snímků je potřeba provést radiometrickou korekci, kdy se převedou hodnoty DN (digital number) na hodnoty spektrální odrazivosti (Deng et al., 2018). Mezi velmi rozšířené multispektrální senzory na trhu patří například již zmíněný Micasense Red-edge MX nebo Sequoia+.

3.4.2 RGB senzory

Dalším velmi užívaným senzorem je RGB kamera. Jedná se o senzor, který je schopný zachycovat snímky ve spektrálních pásmech od 400- 700nm, tedy v oblasti viditelného spektra. Tyto kamery replikují snímky podle vnímání lidského oka, což znamená, že výsledné snímky se jeví v přirozených barvách. V podstatě se jedná o letecké fotografie (Slonecker et al., 2010). Senzor snímá v červeném, zeleném a modrém pásmu viditelného spektra. Použití těchto senzorů je omezeno pouze na bezoblačnou denní dobu. Mezi nejrozšířenější RGB kameru patří například SODA od firmy SenseFly. RGB senzory jsou řádově několikrát levnější než multispektrální či hyperspektrální senzory (Ashapure et al., 2019). Na druhou stranu, ale neposkytují tak detailní informace o stavu vegetace. Nicméně je možné některé typy nákazy nebo poškození vegetace pozorovat i pomocí RGB snímků. Mezi tyto problémy lze zařadit napadení stromů kůrovcem, kdy je možné podle zbarvení korun stromů definovat jednotlivé napadené a mrtvé stromy (MicaSense, 2020). Tyto senzory jsou dobrým nástrojem pro tvorbu kvalitních ortomosaik.

3.4.3 Termální senzory

Dalším z dostupných senzorů pro bezpilotní systémy je termální (infračervený) senzor. Jedná se o senzory, které měří relativní povrchovou teplotu jednotlivých objektů. V podstatě se jedná o běžnou kameru, která vytváří obraz pomocí infračerveného záření s pomocí barevných palet rozlišující teplotní rozdíly. Termální snímky ukazují rozdíly v množství celkové energie záření, z čehož se vypočítá absolutní teplota. Termální senzory se používají například k inspekci budov, kontrole solárních panelů, hledání zdrojů požárů nebo detekci zdravotního stavu vegetace v zemědělství. Senzor nepotřebuje přidaný zdroj světla, tudíž je ho možné provádět i v noci. Tyto senzory jsou schopné vytvářet jak teplotní snímky, tak i teplotní videa. Pro snímání jsou velmi zásadní okolní teplotní podmínky. Mlha, sníh nebo déšť má negativní dopad na tento

typ snímání. Senzory musí být chlazeny, aby výsledky neovlivňovalo jejich vlastní termální vyzařování (Lillesand et al., 2015). Množství vyzařovaného tepelného záření je závislé na emisivitě povrchu objektů. Emisivita je poměr energie vyzařované z povrchu materiálu k energii vyzařované z černého tělesa neboli ideálního vysílače. (NPL, 2020)

3.4.4 Hyperspektrální senzory

Posledním typem UAV senzorů, které nebyly použity během výzkumu, jsou hyperspektrální senzory. Jedná se o senzory, které jsou založené na analýze a vyhodnocení odraženého, také emitovaného záření detekovaného velkým počtem spektrálních pásem na velkém počtu vlnových délek. Zatímco jsou multispektrální kamery schopny snímat data v jednotkách pásem, hyperspektrální senzory jsou uzpůsobené na desítky pásem. Podrobná spektrální charakterizace vlastností povrchu umožňuje použití robustních algoritmů pro získání biochemických a geochemických informací zájmového území (Thenkabail et al., 2011). Data jsou zaznamenávána pomocí trojdimenzových kostek. Každý pixel má data o x, y poloze a dále také o spektrální hodnotě. (GHISA, 2014).

3.5 Fyzikální podstata monitoringu vegetace

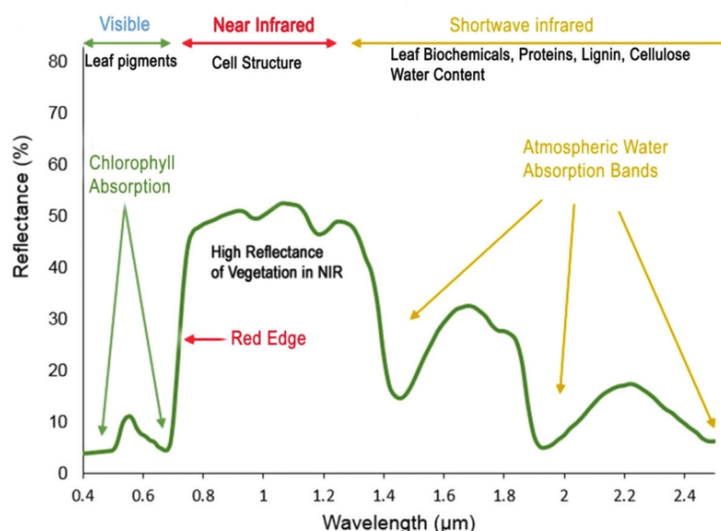
Vegetační pokryv je možné spatřit téměř na každém snímku pocházející z DPZ. Spektrální projev porostu není jednoduchý, ale je výslednicí odrazivých vlastností jednotlivých částí rostlin a pozadí, většinou půdy. Díky rozdílnosti jednotlivých částí stromů se budou lišit i jednotlivé spektrální vlastnosti. Mezi hlavní prvek zobrazený snímku jsou většinou velmi dominantní listy.

V klasickém DPZ využívajícím snímky s různým rozlišením je předmětem zkoumání po většinou ne 1 konkrétní rostlina, ale celé rostlinné společenství. Jedině u záznamů s velmi vysokým rozlišením je možné pracovat i s jednotlivými stromy, i když i zde je vyžadováno plošné mapování (Horák, 2014).

3.5.1 Spektrální vlastnosti listu

Listy rostlin obsahují buněčnou tekutinu, celulózu, tuky, a další organické látky. Spektrální charakteristika rostlin je určena dle výsledku po interakci záření s těmito látkami v listech. Spektrální charakteristika se bude lišit podle zastoupení těchto látek v listech. Tím je možné detekovat různé druhy vegetace. Spektrální vlastnosti se budou druh od druhu velmi lišit, nicméně je možné zobrazit velmi podobný trend pomocí

vegetační křivky, která má 3 hlavní části (viz Obrázek 3): oblast vysoké absorpce, vysoké odrazivosti a vodní absorpce (Horák, 2014).



Obrázek 3: Křivka spektrální odrazivosti vegetace (zdroj: https://www.researchgate.net/figure/The-spectral-reflectance-curve-of-vegetation-The-major-absorption-and-reflectance_fig4_315797574)

3.6 Klasifikace obrazu

Pro získání informace o tom, co se nachází na výsledném snímku z dálkového průzkumu země se využívá klasifikace obrazu. Snímek se rozdělí do jednotlivých tříd, kterým je poté přiřazen informační význam. Výsledný snímek je možné použít k tvorbě tematických map. Podle způsobu rozpoznávání jednotlivých informací se klasifikace rozděluje na pixelovou a objektovou (ArcMap | Documentation, 2015). Klasifikace se dá na základě několika kritérií rozdělit na pixelově orientovanou (pixel based) a objektově orientovanou (object based). Dále je možné klasifikace rozdělit na základě vstupních parametrů daných uživatelem. Poté se klasifikace dělí na řízenou a neřízenou.

3.6.1 Pixelový přístup

Prvním typem klasifikace obrazu je pixelový přístup. Klasifikace obrazu, dle pixelového přístupu, používá hodnoty pixelů v obrazu, aby se rozdělily do různých tříd. Každý pixel je přiřazen do třídy dle svých spektrálních charakteristik. Cílem pixel-based klasifikace je přiřadit všechny pixely v obraze do jednotlivých tříd. Mezi takové třídy patří například hodnoty lesa, řeky, zástavby a další. Počet tříd a jejich typ je určen přednostně uživatelem. Pro řízenou klasifikaci lze použít mnoho různých algoritmů. Detailně budou představeny jen ty, které jsou součástí metodické části řešení práce. (Lillesand et al., 2015)

3.6.1.1 Řízená klasifikace


Pro detekci napadených stromů lýkožroutem bylo nutné vstupní snímky klasifikovat. Pro tuto problematiku byla vybrána řízená klasifikace. Řízená klasifikace (supervised classification) je založena na myšlence, že uživatel vybírá trénovací polygony, které jsou reprezentativní pro jednotlivé třídy, a poté software vybere jednotlivé třídy na základě těchto referencí. Pro vytvoření kvalitních trénovacích dat je nutné být dobře seznámen se zájmovým územím a vytvářet jednotlivá data velmi precizně. Podle kvality trénovacích dat se určuje i kvalita výsledné klasifikace. Proces se skládá ze dvou kroků, trénovací a klasifikační. Jednotlivé třídy jsou rozděleny podle spektrální odlišnosti (Jensen J.R., 2015)

3.6.1.1.1 Maximum Likelihood

Dalším typem řízené klasifikace je algoritmus Maximum Likelihood. Často označována jako Gaussova klasifikace maximum likelihood, pracuje na principu počítání pravděpodobnosti, s jakou daný pixel spadá do určité třídy. Vychází z předpokladu, že trénovací data mají normální rozdělení. Při zahušťování a vytvoření shluků pixelů se hodnotí rozptyl a kovariance vzorů spektrální odezvy. Každý pixel je přiřazen ke třídě, které má nejvyšší pravděpodobnost. Odtud pochází název klasifikace. Hodnoty stejných pravděpodobností poté se spojí v jednu zájmovou třídu (Lillesand et al., 2015)

3.6.1.1.2 Random Forest

Mezi další řízené klasifikace lze zařadit i klasifikátor Random Forest (RF). Klasifikace Random Forest je algoritmus, který využívá metod strojového učení vyvinutý L. Breimanem (Breiman, 2001). Algoritmus se skládá z jednotlivých rozhodovacích stromů, tzv. decision trees. Jedná se tzv. „ensemble“ metodu, což znamená, že klasifikační model kombinuje vícero dat z rozhodovacích stromů (predikce úspěšnosti jednotlivých stromů) do jednoho výsledku. Výsledek je díky tomuto postupu mnohem přesnější (IBM, 2020).



Obrázek 4: Random Forest algoritmus (zdroj: https://www.researchgate.net/figure/Architecture-of-the-random-forest-model_fig1_301638643)

3.6.1.1.3 Minimum Distance

Poslední zmíněnou řízenou klasifikací je Minimum Distance. Klasifikace využívá metodu průměrných vektorů pro každou třídu a následně počítá euklidickou vzdálenost od neznámých pixelů k průměrnému vektoru jednotlivých tříd. Vzdálenost je určena jako index podobnosti, s čehož vyplývá, že čím menší vzdálenost, tím lepší podobnost ke třídě. Pixely jsou klasifikovány podle nejbližší třídy (Wacker & Landgrebe, 1972).

3.6.1.2 Neřízená klasifikace

Další možností, jak vstupní snímek klasifikovat je i varianta neřízené klasifikace. Klasifikace je založena na metodě porovnávání jednotlivých pixelů bez předešlých prostorových či spektrálních informací. Uživatel si určí počet tříd a poté se spektrální třídy rozdělí podle číselné informace v datech. Například se jedná o hodnoty pixelů pro každé z pásem nebo indexů. Klasifikace začíná vytvořením spektrálního grafu, na kterém se vytvoří vstupní počet tříd. Počítač poté data rozdělí do jednotlivých skupin a ty následně upravuje a porovnává na základě průměru, variace, střední odchylky a dalších hodnot. Cílem je, aby došlo k přirozenému statistickému seskupení na základě spektrální podobnosti, tedy aby se uskupení při dalších iteracích výrazně neměnilo (Lillesand et al., 2015)

3.6.1.2.1 Klasifikace k-means

Jednou z neřízených klasifikací je klasifikace k-means. Počítač spočítá střed počáteční třídy rozložené v datovém prostoru. Následně iterativně seskupí pixely do nejbližší třídy pomocí minimální vzdálenosti. Následně v každém kole (iteraci) se přepočítají středy a překlasifikují se pixely podle nového rozložení. Všechny pixely jsou klasifikovány do nejbližší třídy. Tento proces pokračuje, dokud se počet pixelů v každé

třídě nezmění podle vstupní prahové hodnoty nebo dokud nedojde maximálnímu počtu iterací (Tou & Gonzales, 1974).

3.6.1.2.2 Klasifikace ISODATA

Dále mezi neřízenou klasifikaci lze zahrnout i klasifikátor ISODATA. Klasifikace ISODATA funguje na podobném principu jako výše zmíněná klasifikace k-means. Rozdíl je v tom, že při klasifikaci k-means je počet tříd vstupní parametr, ale při klasifikaci ISODATA je počet tříd předem neznámý. Pixely jsou rozděleny do tříd, pokud je počet pixelů ve třídě menší než určitá prahová hodnota nebo pokud jsou střední hodnoty dvou tříd blíže než určité hodnotě (Tou & Gonzales, 1974).

3.6.2 Objektový přístup

Třetím typem klasifikace snímků z dálkového průzkumu země je klasifikace Objektová. Tato klasifikace je založena na kombinování spektrálních a prostorových informací. Jednotlivé pixely se rozdělí na základě spektrálních charakteristik, tvaru, textury a podle prostorového vztahu s ostatními pixely. Vztah mezi pixely se zjišťuje podle určitého propojení mezi objekty, nebo podle vzdálenosti k dalším objektům. Obrazové objekty jsou skupiny pixelů, které jsou si podobné na základě výše zmíněných charakteristik. Tento proces probíhá ve dvou hlavních krocích. Segmentace a rozdělení na jednotlivé objekty a následná klasifikace objektů (Liu & Xia, 2010).

3.7 Lýkožrout smrkový

3.7.1 Taxonomie

Lýkožrout smrkový patří pod kmen Antropoda (členovci) a řád Coleoptera (brouci). Konkrétně se jedná o čeleď Curculionidae (nosatcoviti) (*Ips Typographus* (Lýkožrout Smrkový) | BioLib.Cz, 2017).

3.7.2 Výskyt

Lýkožrout smrkový se vyskytuje převážně ve starších smrkových lesech (kolem 60 let). Nejčastěji je možné ho nalézt na osluněných porostních stěnách (Lýkožrout Smrkový | Kůrovcové Info 2016). Výskyt lýkožrouta je spojen s celkovým zdravotním stavem porostů (Trgala, 2019). Dlouhodobý nedostatek srážek vede k poklesu vitality stromů. Takto stresované stromy jsou náchylnější k napadení Lýkožroutem (Krokene

& Liebhold, 2020). Pro zamezení rychlého šíření je důležité provádět včasná a účinná preventivní opatření (Výzkumný ústav lesního hospodářství a myslivosti, 2019). Mezi hlavní druhy stromů, které lýkožrout napadá, patří smrk ztepilý a další druhy smrkových porostů, nicméně může napadat i modřiny nebo vzácně i borovici lesní (Lýkožrout Smrkový | Kůrovcové Info, 2016). Prakticky ve všech smrkových porostech je možné zachytit jeho aktivitu (Lýkožrout Smrkový Ips Typographus (L.), 2007).

3.7.3 Potrava

Larva lýkožrouta se živí primárně lýkem stromů převážně stresovaných porostů. Prioritně, ale napadá odumřelé stromy (například dříví z těžby nebo spadlé mrtvé stromy), avšak při přemnožení se rozšiřuje i na zdravé stromy (Krokene & Liebhold, 2020).

3.7.4 Reprodukční cyklus

V nižších polohách má lýkožrout smrkový většinou dvě generace ročně, nicméně při příznivých podmínkách může mít i o jednu generaci více. Rojení během jara začíná na rozhraní dubna a května. Ve vyšších polohách je tato doba opožděna, hlavně v důsledku teploty. Letní rojení nastává zhruba po 8 až 10 týdnech od začátku rojení jarního. Pokud nastane třetí rojení, objevuje se většinou na přelomu srpna a září. Po 2 až 3 týdnech od začátku jarního rojení nastává tzv. sesterské rojení. Sesterské rojení je přerojování samic na stejný nebo případně jiný strom. Během svého života naklade samička průměrně 60 vaječ (Lýkožrout Smrkový Ips Typographus (L.), 2007).

3.7.5 Poškození lesa

Larvy se živí lýkem stromů, čímž způsobí jeho postupný zánik. Napadený smrk v místech, kde se brouk do stromu zavrtal se objevují hromádky drtinek spleené smůlou. Barva jehličí se mění a strom světlá. V místech náletu začíná opadávat kůra. V případě, že dojde k rychlému vývoji lýkožrouta opadá kůra dřívě, než se mění jeho barva. Pod kůrou napadeného stromu se nachází požerky (Lýkožrout Smrkový Ips Typographus (L.), 2007).

3.7.6 Přirození nepřátelé

Lýkožrout má mnoho přirozených nepřátel nejenom mezi lidmi, ale i v přírodě. Mezi nepřátele spadají jak predátoři, tak i parazitoidi. Mezi nejznámějšího predátora tohoto

brouka patří brouk pestrokrovečnick mravenčí (*Thanasimus formicarius*) spadající pod čeled' pestrokrovečnickovitých. Velmi častí parazitoidi jsou cizopasnici z řádu blanokřídlých, například lumčici (*Braconidae*). Dalšími cizopasníky jsou některé druhy roztočů a hlístic. Například hlístice rodu *Tylenchus* (Krokene & Liebhold, 2020).

3.7.7 Prevence

V současné době jsou známy tři možnosti prevence proti lýkožroutu smrkovému. Zaprvé před začátkem rojení zpracovat veškeré dřevo, které by bylo vhodné pro vývoj lýkožrouta. Další možností prevence je odstranění veškerého napadeného stromového materiálu. Posledním krokem je cílené hubení lýkožrouta pomocí lapáků. Ochrana potencionálního dříví proti napadení lýkožroutem se realizuje pomocí chemické asanace (Lýkožrout Smrkový *Ips Typographus* (L.), 2007). Někdy se realizuje prevence pomocí podpory hmyzožravého ptactva (Lýkožrout Smrkový | Kůrovcové Info, 2016).

3.8 Práce dalších autorů a jejich napojení na moji práci

Před začátkem výzkumu bylo nutné udělat rešerši dosavadní práce různých autorů v oblasti detekce napadených stromů kůrovcem. Níže je pár vybraných prací blíže přiblíženo.

Timing of red-edge and shortwave infrared reflectance critical for early stress detection induced by bark beetle (Abdulah et al., 2019):

Cílem práce bylo prokázat, zdali vlastnosti listů a odrazivost korun stromů bude sloužit k detekci stresu způsobeným kůrovcem. Data se rozdělila na zdravé a čerstvě napadené stromy. Celkem bylo vybráno 120 stromů, rozdělených do 30 území zdravých a 8 nakažených. Terénní pracovníci sebrali ručně vzorky, které analyzovaly spektrometrem. Tím byl spočítán celkový obsah chlorofylu. Multispektrální data pocházela ze SPOT a RapidEye družic s vysokým prostorovým rozlišením. Data ze SPOT obsahovala 5 pásem. Z dat colored infrared snímků se vytvořily vektorová data napadených stromů. Z listů se počítaly rozdíly mezi třídami RMSE. Dále bylo provedeno velké množství spektrálních indexů. Hodnoty celkové koncentrace chlorofylu byly u nakažených stromů nižší než u zdravých. Podobný trend byl i u ostatních leaf traits indexů (obsah vody, chlorofyl, koncentrace dusíku). Studentův ttest potvrdil významný rozdíl mezi zdravými a napadenými stromy. Tato práce je jedna z mála, věnující se otázce použití red-edge a termálního spektra k detekci kůrovce. Slouží jako inspirace.

The use of UAV Mounted sensors for precise Detection of Bark Beetle Infestation (Klouček et al., 2019):

Cílem práce bylo prokázat, zdali lze použít bezpilotní prostředek s levnou RGB kamerou a upraveným infračerveným senzorem k detekci kůrovce. Studie byla provedena v KRNAPu, v neřízeném pásmu severní části České republiky, kde je šíření kůrovce pomalejší. Z nasnímaných dat byla vytvořena orthomosaika, které byla následně radiometricky kalibrována na povrchovou odrazivost. Bylo vypočítáno 5 vegetačních indexů a provedena klasifikace na napadené a zdravé stromy ve čtyřech časových obdobích pomocí klasifikátoru Maximum Likelihood. Výsledky prokázaly, že i méně finančně náročnou kameru lze použít k detekci aktivity lýkožrouta. S přibývajícím časem po nakažení je detekce prokazatelnější. Nejúčinnější z testovaných spektrálních indexů byl index greenness s celkovou přesností 78-96 %. Výsledky blíží se NIR pásmu nebyly prokazatelné. Tato práce má návaznost na moje téma bakalářské práce.

Use of a multispectral UAV photogrammetry for detection and tracking of forest disturbance dynamics (Minařík et al., 2016):

Práce pojednává o použití multispektrálních dat z bezpilotních prostředků k detekci a sledování lesních disturbancí. Oblastí výzkumu byla Šumava. Pro výzkum byla využita multispektrální data s vysokým rozlišením. Senzor umístěný na bezpilotním prostředku byl upraven o set filtrů schopných detekovat stres vegetace způsobený lýkožroutem. Celkem bylo pořízeno 200 snímků, tvorba orthomosaiky a tvorba DTM. Dále se pomocí spektrální variability vytvořili trénovací data pomocí kruhu rozdělené na zdravé, napadené stromy, zeleň, mrtvé stromy a výsadba nových stromů. Vypočítalo se několik spektrálních indexů. Snímky s vysokým rozlišením umožnily studovat vnitřní strukturu a dynamiku. Nejužitečnější pásma pro detekci stresu způsobenou kůrovcovou aktivitou byla pásmo 2 (650nm), pásmo 3 (700nm) a pásmo 4 (800nm) z red-edge a NIR části. Tato práce má návaznost na moje téma bakalářské práce.

Automatic Tree Crown Extraction from UAS Multispectral Imagery for the Detection of Bark Beetle Disturbance in Mixed Forests (Minařík et al., 2020):

Cílem práce bylo vytvořit automatickou extrakci korun stromů z multispektrálních snímků pro detekci narušení kůrovcem ve smíšených lesích. Zájmové území byl les Klánovice v Praze. Během výzkumu byla použita data ze senzoru MicaCase red-edgeMX a snímky pásma RGB+red-edge+NIR. Vypočítaly se základní metriky pro

vybrané velké stromy. Koruny těchto stromů se předělali do formy polygonů. 122 stromů slouží jako reference. Přesná ortoretifikace byla provedena na vstupních snímcích. Využitím „raster calculator“ se spočítali spektrální indexy. Postup extrakce korun:

- vytvoření masky vegetace bez stínů
- vytvoření vegetační masky pomocí excess green index
- přidání k indexu masky stínů vytvořené z NIR dat
- klasifikace k-means rozdělila masku do 5 tříd podle potenciálu detekce stínů

Pro automatickou detekci korun se použily 3 metody – dalponte2016, marker – controlled watershed, a srovnávací studie Xiao a Hastings. Dále se vypočítal výškový model.

Aplikace prahové masky ExG vedla k vynikající oddělitelnosti cílených jehličnatých stromů a ke zvýšení tvarové podobnosti. Dospělo se k závěru, že automatické metody ITCD mohou představovat náhradu za časově náročné ruční vymezení korun stromů při detekci narušení kůrovce a sanitaci jednotlivých napadených stromů. Tato práce má návaznost na moje téma bakalářské práce.

A Comparative Study of RGB and Multispectral Sensor-Based Cotton Canopy Cover Modelling Using Multi-Temporal UAS Data (Ashapure et al., 2019):

Cílem práce bylo porovnání RGB a multispektrálního přístupu k modelování bavlněných korun. Nejprve byl spočítán index NDVI, který sloužil jako reference pro RGB snímky. Dále byla provedena pixelová klasifikace. V dalším kroku se pomocí vzorce vypočítal canopy cover. Následně byla RGB orthomosaika přetvořena na binární snímek 0 = noncanopy 1 = canopy. Pro multispektrální data se pomocí NDVI oddělila canopy cover od zbytku a pro určení přesnosti canopy cover byla provedena pixel klasifikace k-means s přesností 97 %.

Pro několik let sbírané snímky byla metoda CC analýzy stabilní a přesná. Existuje korelace mezi CC analýzou RGB a multispektrálních snímků. U RGB analýz byla metoda RGBVI víc tolerantní ke změně barev v korunách stromů. CC analýza založená na RGB datech měla stejnou přesnost jako při využití multispektrálních dat. V budoucnu bude možné používat více RGB snímků k těmto druhům analýz. Tato práce má návaznost na moje téma bakalářské práce.

Coastal Dune Vegetation Mapping Using a Multispectral Sensor Mounted on an UAS (Suo et al., 2019):

Cílem práce je mapování vegetace pobřežních dun pomocí multispektrálních dat z UAV. Vstupní data byla z parrot sequioa snímky RGB + NIR a red-edge. Zájmové prostředí bylo na východním pobřeží Irska. Zaprvé bylo zapotřebí vytvořit v zájmovém území kalibrační desky, jejichž poloha byla zaměřena pomocí GNSS. Provedla se radiometrická kalibrace multispektrálních snímků. Dále se vytvořily georeferencované orthomosaicky, DSM, vrstva vrstevnic, 3D potincloudu. Orthomosaicka byla klasifikována na 12 typů algoritmem maximum likelihood.

Nejlepších výsledků ze snímků vysokého rozlišení bylo dosaženo pomocí 8 spektrálních pásem RGB + 4 pásma multispektrální + index NDVI. Celková přesnost byla 78 %. Bez použití NDVI indexu byla přesnost pouze 75 %. Klasifikace pouze multispektrálních snímků byla horší než pouze RGB. Celkem klasifikace dokázala velmi přesně identifikovat jednotlivé vegetativní druhy. Tato práce má návaznost na moje téma bakalářské práce.

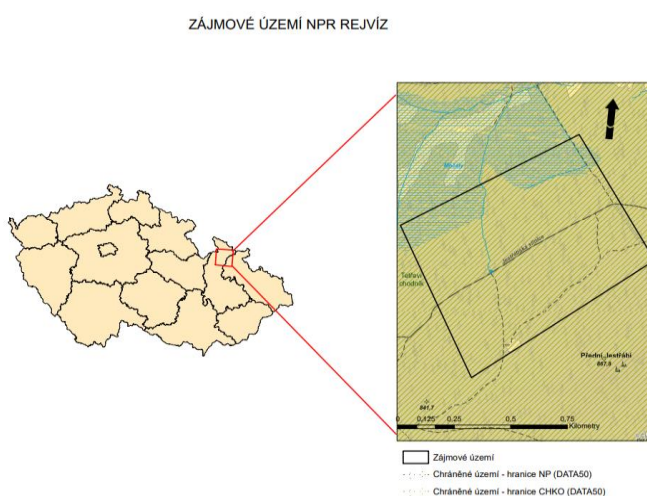
Tabulka 1: Předešlé výzkumy detekce kůrovcové aktivity

Č.	Autor	Použitá data
1	Marx et. al 2010	RapidEye
2	R. Nási et. al 2015	Hyperspektrální data a UAV fotogrametrie
3	E. Honkavaara et. al 2018	Hyperspektrální, multispektrální a RGB UAV snímky
4	R. Nási 2018	Hyperspektrální UAV snímky
5	H. Abdullah et. al 2019	SPOT a RapidEye multispektrální snímky a terénní měření
6	H. Abdullah et. al 2019	Landsat 8 snímky (obsahuje i termální pásmo) a terénní měření
7	H. Abdullah et. al 2019	Landsat8 a Sentinel 2 (NIR a SWIR) snímky
8	T. Klouček et. al 2019	RGB a NIR UAV snímky
9	M. Kampen et. al 2019	Multispektrální UAV snímky
10	A. Ashpure et. al 2019	RGB a multispektrální UAV snímky
11	M. Hollaus et. al 2019	Radarová satelitní data

4 Charakterizace zájmového území

Naše oblast výzkumu probíhala v národní přírodní rezervaci (NPR) Rejvív, podél Jestřábí stezky. Stezka se nachází na pomezí hospodářského lesa a přírodní rezervace. Na tomto pomezí by měl být velice snadno viditelný rozdíl mezi šířením kůrovce v rozdílných typech prostředí. Je to ideální místo pro zkoumání detekce kůrovce.

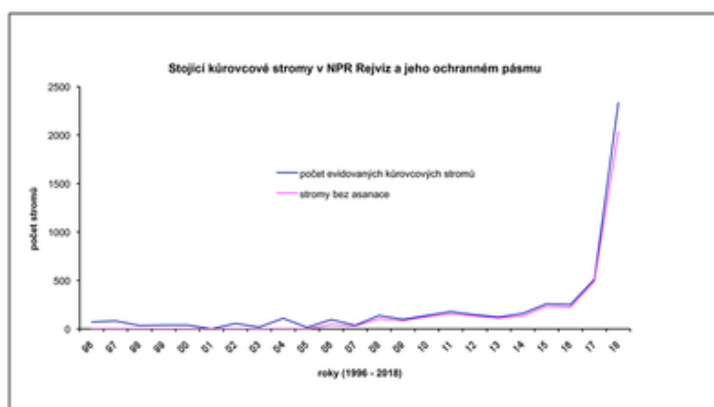
NPR se nachází v Olomouckém kraji, konkrétně v okrese Jeseník. Rezervace má rozlohu 328 ha a nachází se v nadmořské výšce 731-805 m. Území spadá pod zvláštní ochranu od roku 1955 (Národní Přírodní Rezervace Rejvív, 2014). Hlavním důvodem, proč je toto území pod ochranou, je komplex rašelinných ekosystémů s celkovou rozlohou 226,6 ha (Geologické Lokality – Rejvív, 2016). Na ekosystém jsou vázány mnohé druhy rostlin a živočichů. V oblasti je vyhlášené ochranné pásmo čítající rozlohu 68,2 ha (Maloplošná Zvláště Chráněná Území, 2017). Jak je i ze vstupních dat patrné, tak na území převažují lesní biotopy, zejména smrčiny. Ochrana území je prováděna hlavně formou řízeného managementu lesních porostů (Geologické Lokality – Rejvív, 2016). Prostor spadá pod Evropsky významné lokality (Maloplošná Zvláště Chráněná Území, 2017). Dále je zde vymezeno ochranné pásmo.



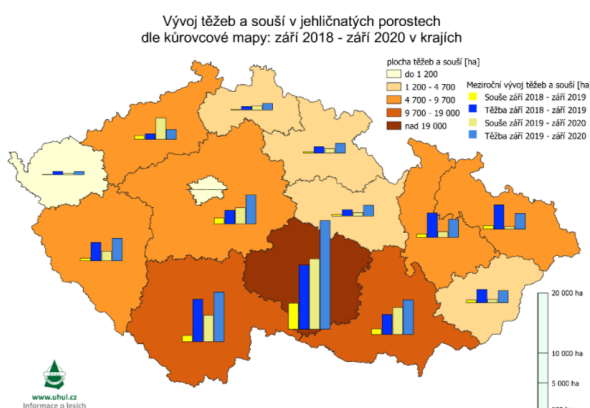
4.1 Rozšíření kůrovce v NPR Rejvív

Díky neustálým průtahům a debatám o rozšiřování bezzásahového území v určitých částech rezervace se kůrovcová kalamita během několika posledních let velmi rozšířila. V roce 2018 se v rezervaci nacházelo téměř pětkrát tolik napadených stromů než v minulosti. Při hledání řešení se účastníci všech stran dohodli pouze na vyloučení chemické asanace již napadených stromů a na rozšíření bezzásahové zóny.

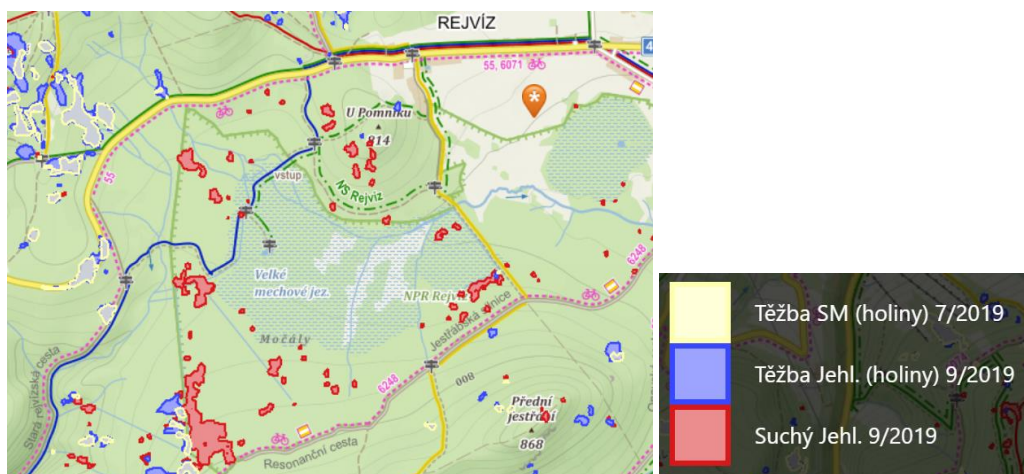
Bezzásahová zóna zahrnovala 82 % lesních ekosystémů v rezervaci. Kácení napadených stromů bylo možné pouze na 9% rezervace. V letech 2018 a 2019 došlo k omezení lesnických prací k odstranění nebo zamezení rozšíření výskytu kůrovce na velkém území rezervace. Dále se na území provádí asanace odkorněním stromů. Dobrým a jednoduchým řešením může být svoz napadených stromů z lesa. Další vývoj kalamity je těžké předvídat. Předpokládá se, že bude množství napadených stromů neustále přibývat. Oblast je od roku 1996 pod dlouhodobým monitoringem šíření kalamity. Výsledky z monitorování slouží k rychlé reakci na její vývoj. Kůrovcovou gradací nejsou zasaženy pouze lesy rezervace, ale se stejným problémem se musí vypořádat i lesníci z okolních lesů. Podle tohoto faktoru, a vývoje klimatických podmínek je predikováno, že na území rezervace by mohlo být napadeno až 90 % vzrostlých smrků do konce roku 2022 (Časopis Ochrany Přírody, 2019).



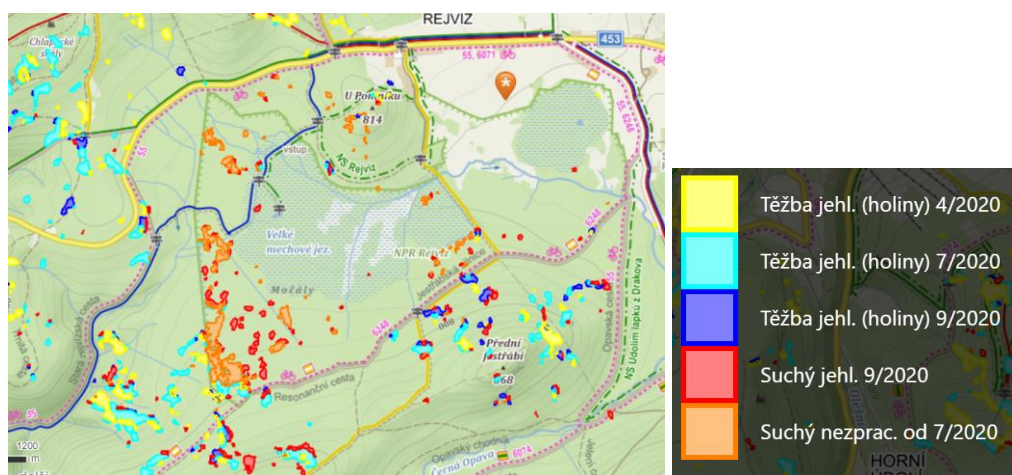
Obrázek 6: Vývoj kůrovcové kalamity v Národní přírodní rezervaci Rejvíz (zdroj: casopis.ochranyprirody.cz)



Obrázek 7: Rozdílová analýza dle členění krajů (Zdroj: kurovcovamap.cz)



Obrázek 8: Kůrovcová mapa 2019 (zdroj: geoportal.uhul.cz)



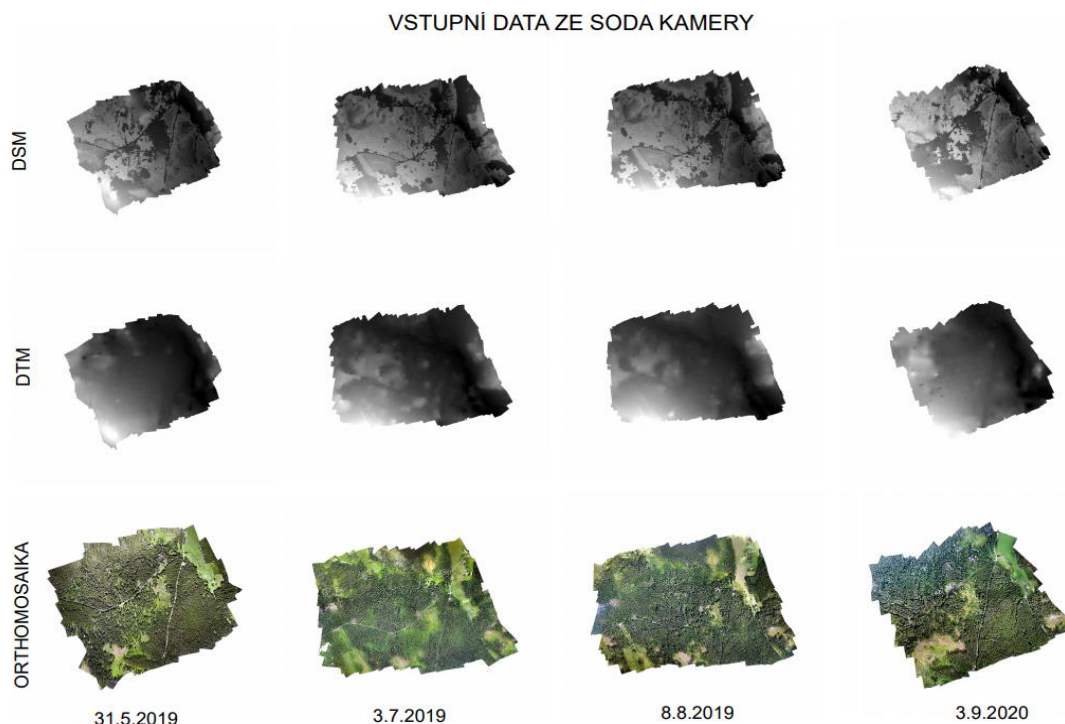
Obrázek 9: Kůrovcová mapa 2020 (zdroj: geoportal.uhul.cz)

5 Metodika

5.1 Vstupní data


Obdržená data jsou výsledkem série náletů v lokalitě NPR Rejvíz. Během výzkumu bylo použito četné množství senzorů umístěných na UAV (viz Tabulka 3). Vstupními daty jsou 4 RGB orthomosaiky zájmového území, nasnímané z období května, července a srpna roku 2019 a září roku 2020, pomocí senzoru SODA (viz Obrázek 10). Rozloha zájmového území je 85 hektarů. Při květnovém náletu byla přesnost. Rozloha červencového snímku bylo 155 hektarů. Rozloha srpnového snímku byla 160 hektarů. Rozloha snímku ze září je 70 hektarů. Přesnost byla 2,5 cm.

Dále byly mezi daty snímky digitálního modelu terénu (DTM) a digitálního modelu povrchu (DSM) opět ze čtyř období a opět pocházející z kamery SODA (viz Obrázek 10). Poslední vstupní data byla z multispektrálního senzoru RedEdge-MX a termálního senzoru thermoMAP, nasnímané v červenci 2019. Jedná se opět o snímky DTM, DSM a orthomosaikou (viz Obrázek 11). Přesnost červencového náletu za použití senzoru Red edge-MX byla 8 cm. Rozloha snímků z ThermoMAP byla. Rozloha ze snímků RedEdge-MX byla 160 hektarů. Rozloha snímků z ThermoMAP byla 165 hektarů. Přesnost červencového náletu za použití senzoru ThermoMAP byla 20 cm.



Obrázek 10: Zobrazení vstupních dat ze senzoru SODA

VSTUPNÍ DATA Z RED EDGE-MX A TERMOMAP KAMER



Obrázek 11: Zobrazení vstupních dat ze senzorů RedEdge-MX a ThermoMAP

5.1.1 Použité senzory během výzkumu

Prvním z použitých senzorů během našeho výzkumu byla kamera SODA. Jedná se o fotogrammetrickou kameru pocházející od firmy SenseFly (viz Obrázek 12). Jedná se o jeden z nejpoužívanějších senzorů v oblasti dronů na trhu. Kamera slouží k zachycování velmi přesných a ostrých leteckých snímků. Výstupem z těchto dat mohou být například velmi detailní orthomosaiky nebo přesné digitální modely povrchu. Kamera má pouze jeden RGB senzor. Formát snímků je v JPEG. Kamera má rozlišení 20 MP (SenseFly, 2017).




Obrázek 12: senzor SODA

Dále byl během výzkumu využit senzor RedEdge-MX. Je to profesionální multispektrální kamera vyvinutá speciálně pro nasazení v zemědělství. Kamera pochází od firmy SenseFly (viz Obrázek 13). Sensor snímá v 5 pásmech ve vysokém rozlišení. Pásma jsou R (668nm), G (560nm), B (475nm), red-edge (717nm) a NIR (840nm). Senzor dosahuje velmi vysoké přesnosti, až 8 cm na pixel při 120 m ve vzduchu. Přesnost je ovlivněna výškou letu UAV. Formát snímků je TIFF. Senzor je připravený pro opakovaná terénní měření. Před začátkem měření je nutné provést kalibraci. Ta se provádí pomocí kalibrovaného panelu odrazivosti. (MicaSense, 2019).



Obrázek 13: senzor RedEdge-MX

Jako poslední byl během výzkumu použit termální senzor ThermoMAP. Jedná se o termální infračervenou kameru pocházející od firmy MicaSense (viz Obrázek 14). Senzor dosahuje přesnosti až 14 cm na pixel při výšce 75 m nad zemí. Umožňuje vytvořit jak termální video, tak i samostatné termální snímky. Ke kalibraci teploty dochází během snímání. Senzor snímá ve spektrálním rozmezí 7500-13500 nm. Formát snímků je opět TIFF. Senzor váží 134 g (The Professional Mapping Drone, 2016).



Obrázek 14: senzor ThermoMAP

Tabulka 3: Využité senzory během výzkumu

Název	Rozlišení	Snímaná pásma	Cena	Formát	Datum snímání	Velikost dat
S.O.D.A.	RGB 20 MP (3:2)	3 - RGB	40 000 Kč	JPEG /DNG	31.5. 2019– 3.9. 2020	1,87 GB
Red-edge MX	8 cm/pixel	5 - RGB, red-edge, NIR	110 000 Kč	TIFF	3.7. 2019	3,46 GB
ThermoMAP	14 cm/pixel	3 - R, G, termální pásma	260 000 Kč	TIFF	3.7. 2019	34 MB

5.2 Pre-processing vstupních dat

Prvním krokem bylo nutné snímky z července georeferencovat provedením pomocí programu Arcmap a pomocí nástroje georeference. Ručně jsem vybral body na dvou snímcích a poté jsem transformaci uložil přímo do vrstev pomocí update georeference.

Dalším krokem bylo vstupní snímky oříznout na menší území, pro sjednocení území na všech snímcích. V Arcmapu jsem vytvořil polygon a pomocí nástroje „extract by mask“ došlo k ořezání snímků.



Květen 2019, SODA orthomosaika



Červenec 2019, SODA orthomosaika




Srpen 2019, SODA orthomosaika




Září 2020, SODA orthomosaika

Obrázek 15: sjednocené vstupní SODA orthomosaiky

Pro sjednocení území na vstupních termálních a multispektrálních datech, jsem opět použil stejný polygon a nástrojem „extract by mask“ jsem udělal ořez (viz Obrázek 17). Totéž jsem provedl s digitálními modely terénu a povrchu z termálních a multispektrálních senzorů (viz Obrázek 18).




Červenec 2019 Red edge-MX orthomosaika




Červenec 2019 ThermoMAP orthomosaika

Obrázek 16: sjednocení vstupní multispektrální a termální orthomosaiky



Červenec 2019 Red edge-MX DSM



Červenec 2019 ThermoMAP DSM



Červenec 2019 Red edge-MX DTM



Červenec 2019 ThermoMAP DTM

Obrázek 17: sjednocené vstupní multispektrální a termálních DSM a DTM snímky

5.2.1 Tvorba modelů dat

Pro vytvoření modelů kombinací dat jsem využil nástroj composite band v Arcmapu. Spojení bylo provedeno v kombinaci RGB a termální ThermoMAP. Konkrétně jsem spojil pásma RGB z orthomosaiky z července s termálním pásmem ThermoMAP orthomosaikového snímku. Vznikla kombinace RGB s jedním přidaným pásmem. Data jsou zobrazena ve formě false color composite (NIR, G, R) a v symbologii bylo nastaveno roztažení podle standardní odchyly pro lepší vlastnosti (viz Obrázek 19).




SODA + ThermoMAP orthomosaika

Obrázek 18: Zobrazení kombinace RGB a termálního snímku pomocí kombinace NIR, G, R

5.2.2 Tvorba Canopy Height Modelu

Před vytvořením validačních dat bylo nutné spočítat výškový model CHM (Canopy Height Model). Rastr byl spočítán pomocí vzorce DSM-DTM. Vstupní data do vzorce byla RGB digitální modely povrchu (DSM) a digitální modely terénu (DTM). Podle vzorce výše se nástroj „Raster Calculator“ mezi sebou jednotlivé rastry odečetly.

Za použití nástroje „Raster domain“ jsem vytvořil území ohraničující zájmový CHM rastr a do tohoto prostoru jsem vytvořil 5000 náhodných bodů pomocí nástroje „Create random points“ (viz Obrázek 28). Do vstupních parametrů bylo zadáno 1m rozestupy mezi samotnými body, aby nedocházelo k překryvu a jako další parametr byla použita dříve vytvořená „Raster domain“, aby došlo k zobrazení vytvořených bodů do plochy zájmového rastru.



Obrázek 19: Zobrazení náhodných bodů v CHM rasteru

Hodnoty z rasteru CHM jsem převedl do těchto bodů pomocí funkce „Extract values to point“. V dalším kroku došlo k exportu atributové tabulky bodů pro další použití a vizualizaci hodnot. Pro statistické zhodnocení dat byl použit software R. Hodnoty CHM se zobrazily ve formě boxplotů.


Stejným postupem jsem vypočítal CHM raster z dat ze senzorů RedEdge-MX a thermoMAP. Opět se vytvořilo ohraničení rasteru pomocí „Raster domain“ a do tohoto území jsem vytvořil 5000 náhodných bodů s 1metrovým rozestupy mezi sebou, aby nedocházelo k případným překryvům. Následně byly hodnoty přepsány do bodů a zobrazeny v software R metodou boxplotů.

5.2.3 Tvorba referenčních dat

Pro klasifikace sjednoceného zájmového území bylo potřeba vybrat referenční trénovací data, která by během délky výzkumu byla patrná na všech snímcích. Z horní části dat, tedy bezzásahové oblasti rezervace, jsem vybral celkem 70 stromů. Stromy jsem vybíral polygonovou metodou. Tato data byla poté spojena s Canopy Height Modelem, vytvořeném z předešlých kroků. Pomocí „Raster calculator“ jsem vybral území větší než 10 m. Polygony byly zobrazeny a porovnány s výsledným rastrem CHM (viz Obrázek 20, 21).



Obrázek 20: Zobrazení bodů zdravých stromů v RGB snímku



Obrázek 21: Zobrazení vytvořených trénovacích polygonů v CHM

5.2.4 Klasifikace RGB snímků

Dalším krokem řízené klasifikace byla tvorba dodatečných trénovacích data pro rozdělení celého území dle krajinného pokryvu. Jedná se o polygony zahrnující zeleň, mrtvé stromy a mrtvé dřevo a stíny. Polygony mrtvého dřeva byly velmi detailně vybrány dle tvaru jednotlivých popadaných kusů stromů. Konkrétně pro červencový snímek ze senzoru SODA bylo vytvořeno 26 polygonů mrtvého dřeva, 42 polygonů mrtvých stromů, 70 polygonů zdravých stromů, 65 polygonů zeleně. Dále pro klasifikaci červencové multispektrální orthomosaiky bylo vytvořeno 26 polygonů

mrtvého dřeva, 42 polygonů mrtvých stromů, 171 polygonů zdravých stromů, 108 polygonů zeleně (viz Obrázek 22).




Obrázek 22: Zobrazení trénovacích dat pro RGB ortofoto snímek SODA a trénovacích dat pro termální ortofoto snímek Red edge-MX

Nakonec jsem v softwaru SNAP udělal řízenou klasifikaci s využitím algoritmu Random Forest. Vstup do klasifikace byly vytvořené validační data zdravých stromů a trénovací polygony vytvořené výše. Nastavení algoritmu jsem nijak neupravoval.


5.2.5 Klasifikace zdravých, napadených a mrtvých stromů

Pro analýzu vývoje kůrovcové epidemie bylo použito detailní území v takovém měřítku, aby bylo možné rozeznat tvary jednotlivých korun stromů. Z toho důvodu byly vstupní RGB orthomosaiky oříznuty podle menšího polygonu (viz Obrázek 22).



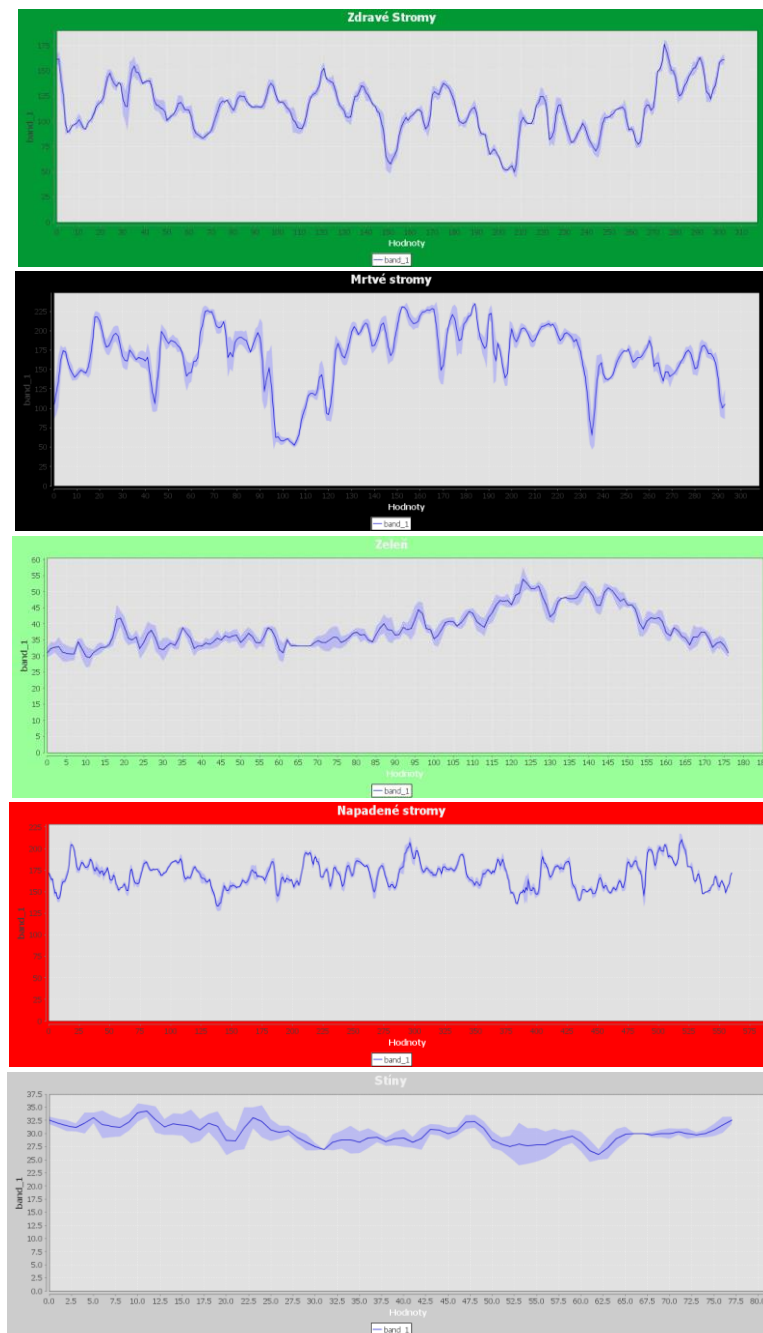
Obrázek 23: Zobrazení vybraného detailního území pro detekci napadených stromů

Opět za použití Canopy Height Modelu jsem ze zájmového území odebral hodnoty menší než 1 metr. Byl k tomu použit nástroj „SetNull“, kdy se všechny hodnoty menší než 1 metr nastavily jako NoData hodnoty. Následně jsem pomocí tohoto rastru a nástrojem „extract by mask“ vytvořil vstupní detailní území RGB orthomosaiky. Výsledkem je rastr s prázdnými místy v oblastech menších než 1 metr (viz Obrázek 23).




Obrázek 24: Zobrazení vstupních ořezů detailního území

Dále bylo nutné vytvořit trénovací data. Pro jejich tvorbu byla zvolena forma polygonů dle tvaru jednotlivých korun stromů. Jako kategorie jsem si stanovil: mrtvé stromy, zdravé stromy a napadené stromy. Dále jsem jako další trénovací data vybral polygony zahrnující zeleň a stíny (viz Obrázek 25). Napadené stromy na RGB snímcích z července a srpna byly vybírány porovnáním se snímkem ze září, který je již po kůrovcovém napadení. Díky tomu všechny stromy, které jsou vybledlejší či jinak zbarvené než obvykle, jsou v předešlých obdobích s největší pravděpodobností napadené kůrovcem. Dalším kritickým faktorem je zdravotní stav stromů. Pokud v pozdějších obdobích přibyly mrtvé stromy v místech kde, v předešlém období byly zdravé, jsou stromy opět napadené lýkožroutem. Jednotlivé trénovací data byla porovnána pomocí spektrální křivky (viz Obrázek 24). V květnu 2019 ještě nedošlo k rojení a následnému napadení lýkožroutem. Z toho důvodu byly jako trénovací data vybrány pouze třídy zdravé stromy, mrtvé stromy a stíny. V červenci už proběhlo kůrovcové rojení, proto bylo nutné do trénovacích dat zahrnout i polygony stromů napadených kůrovcem (viz Obrázek 25).




Obrázek 25: Porovnání spektrálních křivek vybraných tříd



Obrázek 26: Zobrazení trénovací polygony pro měsíc květen a červenec z RGB dat

Dále k detekci napadených stromů byla použita multispektrální a termální data. Před jejich použitím je bylo opět nutné oříznout dle stejného polygonu. Vstupní snímky klasifikace byla RedEdge-MX orthomosaika a ThermoMAP orthomosaika zkombinované s RGB snímkem (viz Obrázek 26). Orthomosaika pocházející ze senzoru ThermoMAP byla nepoužitelná, kvůli špatnému prostorovému rozlišení. Data byly opět zobrazena ve formě false color composite (NIR, R, G).



Obrázek 27: Zobrazení vstupních ořezů detailního území z multispektrálních dat a termálních dat ve formě false color composite

5.2.6 Vyhodnocení přesnosti

Vyhodnocení přesnosti jednotlivých klasifikací bylo provedeno metodou správně klasifikovaných pixelů. Na rastru klasifikace detailního území bylo vytvořeno 10krát

počet klasifikovaných tříd bodů pro měsíc květen 30 bodů a pro ostatní 40 pro každou klasifikační třídu. Na rastru klasifikace celého území bylo vytvořeno 250 bodů. Body byly rozmístěny do prostoru po celém území. Následně jsem těmto bodům vytvořil v atributové tabulce sloupec s číslem označující jednotlivé třídy klasifikace. Tyto body jsem porovnal podle lokality na orthomosaice RGB snímku. Z těchto dat jsem vytvořil chybovou matici (viz Obrázek 29), ze které jsem následně spočítal celkovou přesnost a kappa koeficient podle vzorců. Celková přesnost (Overall Accuracy) se spočítala dle vzorce $OA = (TCS / TS) \times 100$

Sečtením správně klasifikovaných pixelů (v diagonále) a vydělením celkovým počtem bodů. Cohenova kappa se spočítala pomocí vzorce:

$$KC = ((TS \times TCS) - \sum (\text{celkový počet hodnot ve sloupci} \times \text{sečtení hodnot v řádku}) / (TS^2) - \sum (\text{celkový počet hodnot ve sloupci} \times \text{sečtení hodnot v řádku}) \times 100$$

TS= total samples (celkový počet hodnot)

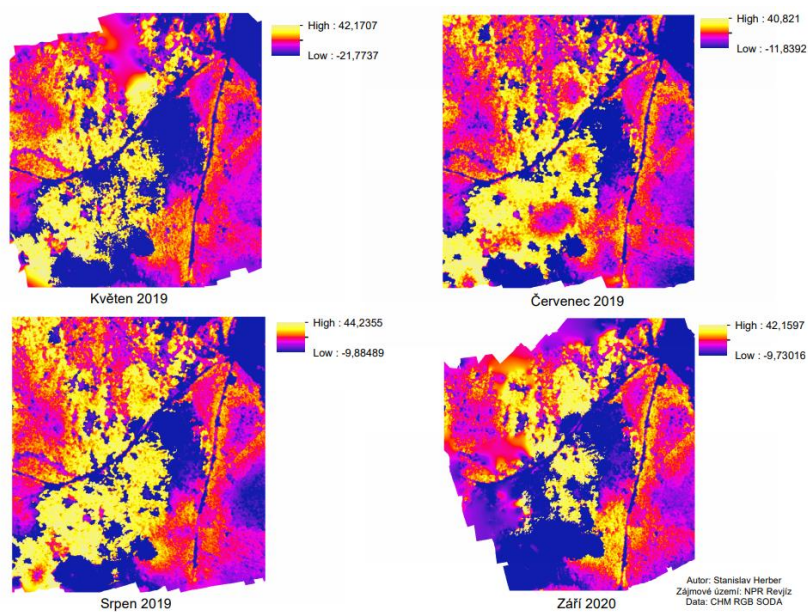
TCS= total classified samples (celkový počet správně klasifikovaných hodnot)

Tabulka 4: Vytvořená chybová matice

květen					
	Random Forest	Skutečnost			
Klasifikátor	Třída	0 Mrtvé stromy	1 Stíny a zeleň	2 Zdravé stromy	celkem
	0 Mrtvé stromy	24	0	6	30
	1 Stíny a zeleň	0	30	0	30
	2 Zdravé stromy	0	0	30	30
	celkem	24	30	36	90
	Celková přesnost	93.3			
	Kappa koeficient	0.94			


6 Výsledky

Výsledný Canopy Height Model z RGB dat sjednoceného území. Z výsledků jsou patrné změny CHM v čase. Při porovnání modelu květnového snímku a snímku ze září jsou vidět rozdíly v množství oblastí s menší výškou. Dále je patrný úbytek oblastí s výškou vyšší než 10 m. Jedná se převážně o vysoké stromy.



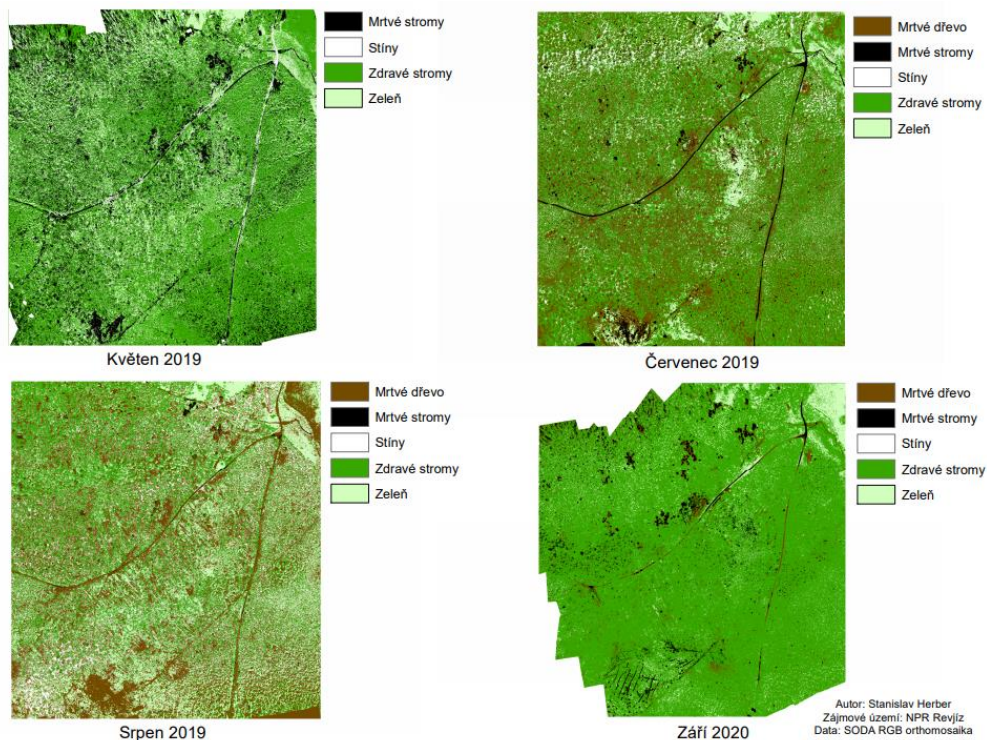
Obrázek 28: Porovnání vytvořeného Canopy Height Modelu z RGB dat (SODA)

Při porovnání Canopy Height Modelu z různých modelů dat jsou patrné četné rozdíly. Model vytvořený z multispektrálních dat vykazuje mnohem prostorově přesnější výsledky, kdežto model z termálních vypadá více uhlazenější, rozdíly ve výškách nejsou tak ostré jako na multispektrálním snímku.



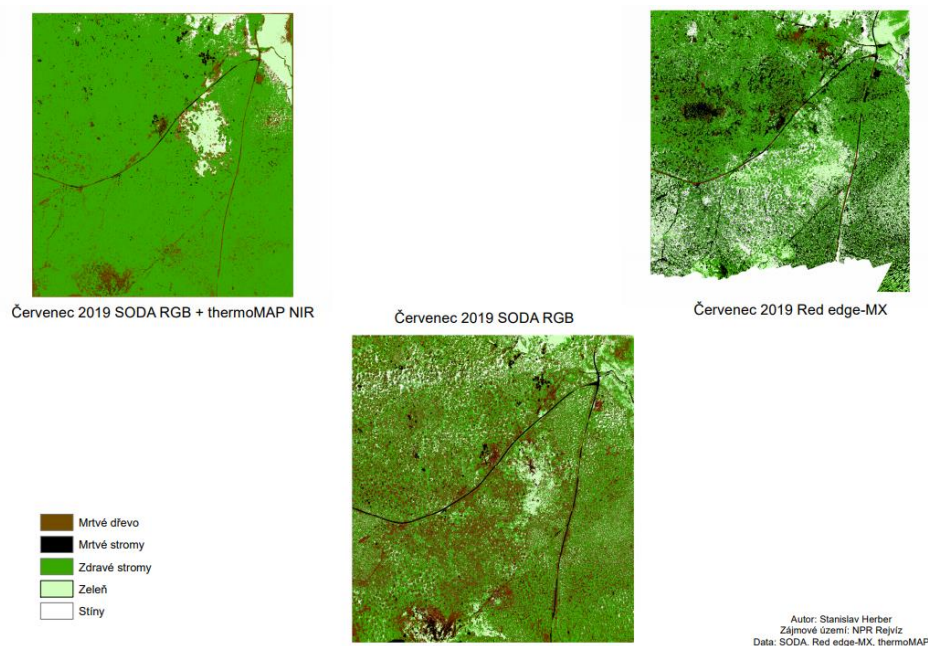
Obrázek 29: Porovnání vytvořeného Canopy Height Modelu z multispektrálních a termálních dat

Výsledná klasifikace sjednoceného území z RGB orthomosaiek pocházejících ze SODA senzoru. Při porovnání časové řady, je na první pohled zřejmé, že na snímku přibývá množství mrtvého dřeva a mrtvých stromů. Nicméně ne všechny klasifikované pixely mrtvého dřeva jsou stoprocentně spadané kusy stromů. Často se jedná o obnaženou hlínu s rozdílným dopadajícím slunečním zářením.



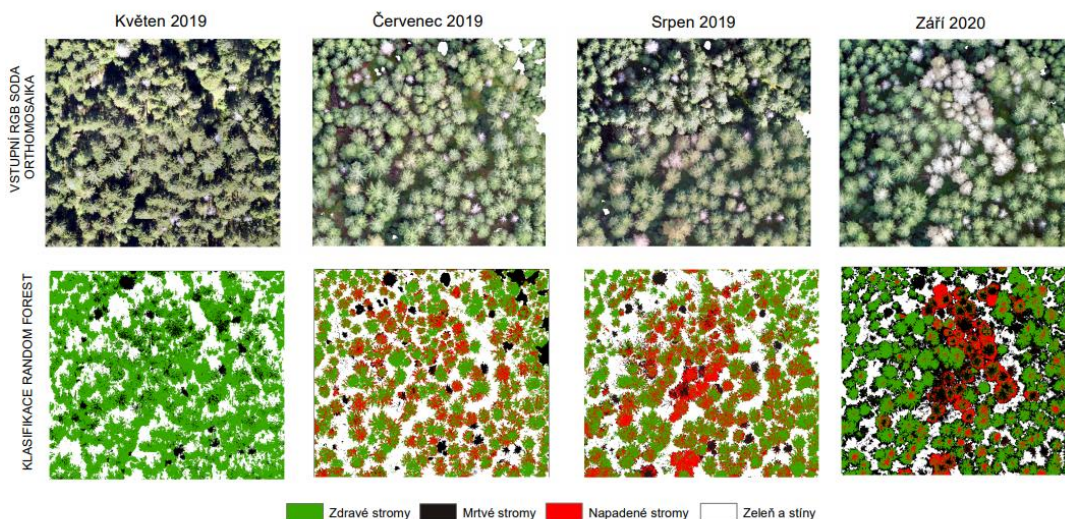
Obrázek 30: Výsledná klasifikace časové řady sjednoceného území

Výsledná klasifikace sjednoceného území z Red edge-MX a SODA RGB orthomosaiek a dále kombinace termálního pásma a RGB snímku. Na první pohled je vidět markantní rozdíl mezi klasifikací multispektrálních a termálních dat.



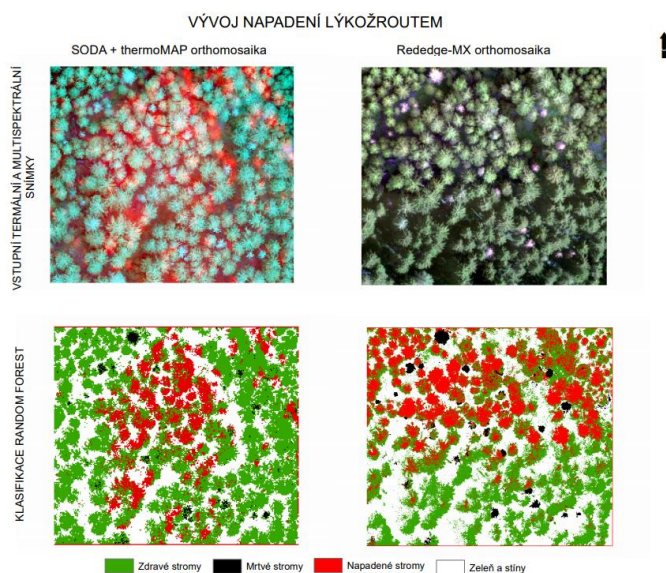
Obrázek 31: Porovnání klasifikace sjednoceného území z termálních a multispektrálních dat

Výsledná klasifikace Random Forest RGB orthomosaiek detailního území, sloužící k detekci jednotlivých napadených stromů. Květnový snímek obsahuje pouze rozdělení zdravých a mrtvých stromů a stínů. V dalších obdobích už byla zařazena kategorie napadených stromů. Ze snímků je patrná rostoucí kůrovcová aktivita v zájmové oblasti. S přibývajícím časem od napadení jsou výsledky mnohem přesnější.



Obrázek 32: Vývoj napadení lýkožroutem v čase (RGB)

Výsledná klasifikace Random Forest multispektrálních a termálních dat detailního území. Porovnání kombinace termálního a RGB snímku s multispektrální orthomosaikou ze senzoru Red edge-MX. Výsledky klasifikace kombinace termálního a RGB snímku jsou velmi přesné s porovnáním klasifikace multispektrálního snímku.



Obrázek 33: Detekce napadených stromů lýkožroutem z multispektrálních a termálních + RGB dat

Tabulka 5: přesností klasifikace sjednoceného území z RGB orthomosaiek pocházející ze senzoru SODA.

SODA ortho snímky			
Květen	Červenec	Srpen	Září
Celková přesnost = 93,3 %	Celková přesnost = 79,6 %	Celková přesnost = 71,2 %	Celková přesnost = 88,75 %
Kappa koeficient = 0,94	Kappa koeficient = 0,74	Kappa koeficient = 0,64	Kappa koeficient = 0,85

Tabulka 6: přesností klasifikace sjednoceného území z kombinace termálního a RGB pásma a dále klasifikace multispektrální orthomosaiky.

Ostatní data	
Červenec 07 Red edge-MX orthomosaika	Červenec 07 ThermoMAP + RGB
Celková přesnost = 82 % Kappa koeficient = 0,77	Celková přesnost = 93,6 % Kappa koeficient = 0,92

Tabulka 7: přesností klasifikace časové řady detailního území, sloužící k detekci jednotlivých napadených stromů, z RGB SODA orthomosaik.

SODA ortho snímky pro detekci napadených stromů			
Květen	Červenec	Srpen	Září
Celková přesnost = 96,9 %	Celková přesnost = 61,25 %	Celková přesnost = 86,25 %	Celková přesnost = 93,12 %
Kappa koeficient = 0,95	Kappa koeficient = 0,47	Kappa koeficient = 0,82	Kappa koeficient = 0,91

Tabulka 8: přesností klasifikace časové řady detailního území z kombinace termálního a RGB pásma a dále klasifikace detailní multispektrální orthomosaiky sloužící k detekci jednotlivých napadených stromů.

Modely dat pro detekci napadených stromů	
Červenec 07 Red edge-MX orthomosaika	Červenec 07 ThermoMAP + RGB
Celková přesnost = 80 % Kappa koeficient = 0,73	Celková přesnost = 95,63% Kappa koeficient = 0,94

Na základě získaných údajů z výsledků klasifikací lze uvést, že:

- Při klasifikaci sjednoceného zájmového území na základní krajinné prvky byly použity RGB orthomosaiky pocházející se senzoru SODA. Výsledky prokázaly, že přesnost klasifikace snímků ze SODA senzoru byla v rozmezí 70-90 %. Nejvyšší klasifikace dosáhl snímek z července s celkovou přesností klasifikace 88,5 % a s kappa koeficientem 0,86. Nejhorší přesnosti klasifikace dosáhl snímek ze srpna s celkovou přesností 71,2 % a kappa koeficientem 0,64 (viz Tabulka 5).
- Při použití detailní RGB orthomosaiky k detekci jednotlivých napadených stromů byla dosažena celková přesnost klasifikace 61,25 % a kappa koeficient 0,47 pro snímek z července. Díky přidání termálního pásma ze senzoru ThermoMAP se přesnost klasifikace zvedla na 95,63 % a kappa koeficient na 0,94. Klasifikace multispektrální detailní orthomosaiky ze senzoru Red edge-MX dosáhla celkové přesnosti 80 % a kappa koeficientu 0,73 (viz Tabulka 8).
- Hodnoty mrtvého dřeva se v průběhu kůrovcového napadení zvyšují, což naznačuje větší míru poškození aktivitou lýkožrouta smrkového (viz graf Časová řada klasifikace SODA ortho snímků).
- S přibývajícím časem od momentu napadení lýkožroutem smrkovým se přesnost detekce jednotlivých nakažených stromů zvyšuje (viz Tabulka 7).


7 Diskuse

Výsledky prokázaly využitelnost termálních dat v oblasti detekce napadených stromů kůrovcem. Nejpresnějších výsledků bylo dosaženo právě spojením termálního pásma s RGB orthomosaikou. Při spojení RGB a multispektrálního snímku byla získaná přesnost obecně vyšší než u samotné RGB orthomosaiky. S přibývajícím časem od momentu napadení kůrovcem je jeho detekce snazší. Nicméně při použití termálních snímků je jeho detekce možná v kratší době po napadení stromů než u snímků RGB. Nejvyšší přesnosti klasifikace sjednoceného zájmového území bylo také dosaženo použitím kombinace RGB a termálního snímku z Red edge-MX senzoru. Vědeckých studií týkající se použití termálního pásma z UAV při detekci kůrovce v dnešní době není mnoho. Má bakalářská práce se zabývá podobnou tematikou jako výše zmíněná studie profesora H. Abdullah Ph.D., kdy během zkoumání kůrovce byly použity red-edge a termálního data. Profesor potvrdil hypotézu, že se dají pozorovat markantní rozdíly v povrchové teplotě mezi zdravými a napadenými stromy. Hodnota při provedení studentova t testu byla menší než 0,05. Dále potvrdil, že lze pozorovat rozdíly v jednotlivých listových vlastnostech mezi zdravými a napadenými stromy. Z výsledků prokázal využití povrchové teploty stromů jako jeden z rozdělovacích faktorů mezi zdravými a napadenými stromy. Nakonec stejně jako při mém výzkumu, termální data vykazovaly lepší výsledky při klasifikaci zdravých a napadených stromů.

Jednou z nevýhod, které přináší práce s multispektrálními snímky je fakt, že při snímání velkého zájmového území vznikají v datech, z důvodu změny slunečních podmínek, pruhy. Tomu nelze zamezit a je proto nutné s tím počítat. Výsledky to rámcově činí méně přesnými, nicméně je možné při klasifikaci tento vliv zmírnit použitím více trénovacích v jednotlivých oblastech těchto změn. Další nevýhoda spojená s multispektrálními snímky je jejich velikost. Tyto data zabírají téměř dvakrát tolik místa, co RGB snímky. RGB orthomosaika z červencového snímání zabírá 1,84 GB, kdežto orthomosaika pocházející z multispektrálního snímání má 3,46 GB. Není to nějak zásadní problém, jen je dobré to mít na paměti. Práce s celými snímky je výpočetně velmi náročná, tudíž doporučuji použít menší území, což pro náročnější výzkumy nemusí být reálné.

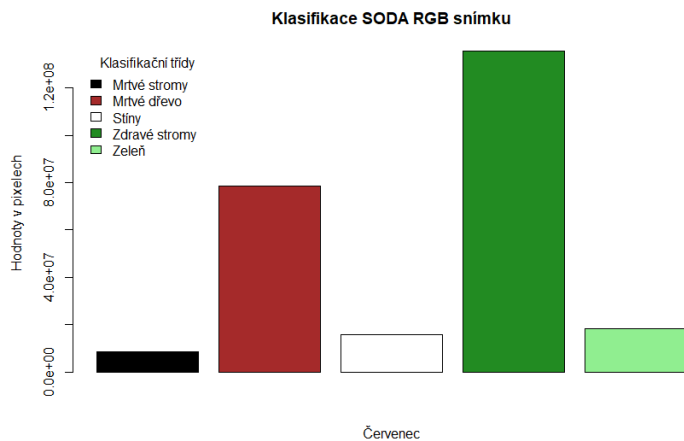
V neposlední řadě je nutno zmínit i cenovou náročnost multispektrálních a termálních senzorů v porovnání s klasickými RGB kamerami. Red-edge MX, který byl použit během mého výzkumu, se finančně pohybuje v až 4krát vyšších částkách než klasická RGB kamera, v našem případě SODA kamera. Použitý termální senzor ThermoMAP je ještě dražší.

Porovnání klasifikace sjednoceného území z RGB dat ze senzoru SODA, metodou sloupcového grafu:

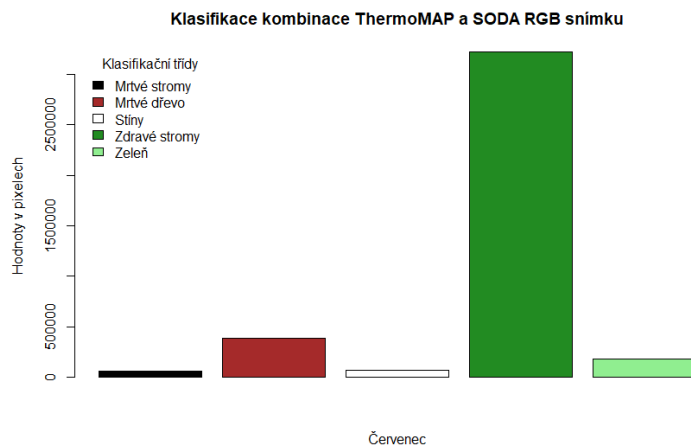


Z grafu klasifikace sjednoceného území z RGB dat je patrné, že hodnoty spadaného a mrtvého dřeva v roce 2019 výrazně rostou. Nicméně při porovnání se snímkem ze září z roku 2020 jsou patrné velké rozdíly, jak v množství mrtvého dřeva, tak i samotných mrtvých stromů. Snímky z roku 2019 se odehrávaly během přímé aktivity kůrovce, z čehož lze usuzovat, že se zvedá počet mrtvého, spadaného dřeva a výrazně ubývá množství zdravých stromů. Na druhou stranu konkrétně v této oblasti nastává vcelku rychlá odezva na kůrovcovou aktivitu, především kácením napadených stromů a odklizení spadaného materiálu, který by sloužil jako potenciál pro další rozmach kůrovcového rojení.

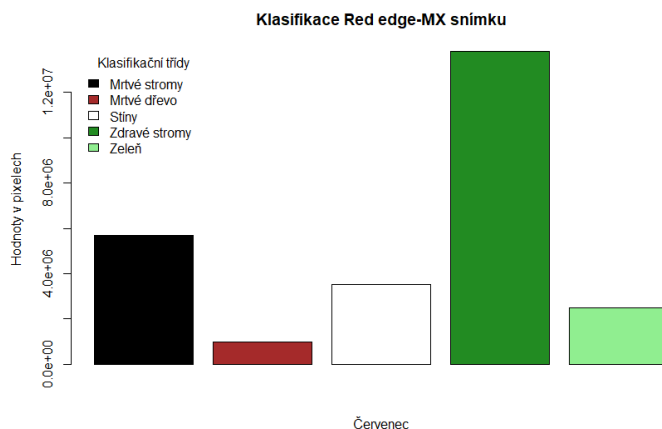
Porovnání klasifikace sjednoceného území z července z RGB dat ze senzoru SODA, metodou sloupcového grafu:




Porovnání klasifikace sjednoceného území z července, z kombinace termálního (ThermoMAP) a RGB pásma, metodou sloupcového grafu:



Porovnání klasifikace sjednoceného území z července, za použití multispektrálního senzoru, metodou sloupcového grafu:




Z porovnání je patrné, že na snímcích byly stále dominantní hodnoty zdravého lesa. Nejvyšších hodnot, zastoupených v pixelech, dosahoval právě zdravý les. Co se týče klasifikace mrtvých stromů byl nejkvalitnější SODA RGB snímek. Na kombinaci termálního a RGB snímku se neklasifikovaly téměř žádné a na snímku z Red edge-MX jich bylo velmi hodně. Je to hlavně z důvodu „pruhů“ v datech. Ty vznikly během snímání, když nastala změna slunečních podmínek. Nelze se tomu vyvarovat. Mrtvé dřevo bylo opět klasifikováno nejpřesněji na SODA RGB snímku.



Z grafu pozorují, že se střední hodnoty v průběhu času velmi mění. Nejdříve hodnoty lehce stoupají, nicméně při porovnání prvního a posledního snímku pozorujeme, že hodnoty CHM se zmenšují. Zmenšuje se nejenom celkový rozsah hodnot, ale i především střední hodnota. Ze zmenšujících se hodnot usuzují, že se na snímku nachází více oblastí bez stromů, více luk nebo zeleně. Vzhledem k častějším hodnotám s nižší výškou lze usuzovat, že rozloha lesa ubývá. Jedním z důvodů může být právě napadení stromů lýkožroutem smrkovým. Index slouží jako další ukazatel ubývajícího počtu lesa v mém zájmovém území.

Z porovnání výsledných Canopy Height Modelů je vidět, že správné a přesné jsou pouze CHM pocházející z dat digitálního modelu terénu a povrchu ze senzoru SODA a Red edge-MX. Při výpočtu modelu ze dat ze senzoru ThermoMAP byl výsledek špatný, protože se v grafu se nachází velké množství outlier bodů. Z toho lze usuzovat, že bude výsledek nedosahuje takové přesnosti jako výsledky z ostatních dat.



8 Závěr

Cílem mé bakalářské práce bylo prokázat využitelnost bezpilotních systémů v oblasti detekce kůrovcové aktivity v NPR Rejvíz. Výsledky potvrdily využití dat z bezpilotních systémů, konkrétně využití termálních dat k detekci napadených stromů. Klasifikace termálních dat v kombinaci s RGB snímky dosahuje nejvyšší přesnosti. Proto se domnívám, že právě zmínění kombinace dat by mohla být nejideálnějším způsobem detekce napadených stromů lýkožroutem. Práce slouží jako nastínění využití termálních dat v oblasti detekce lesních disturbancí. Tato metoda přináší velmi kvalitní výsledky, které by mohly sloužit jako inspirace při dalších výzkumech. Osobně se domnívám, že se v blízké budoucnosti budou k detekci lesních disturbancí využívat převážně multispektrální a termální data.

Díky danému výzkumu byly zodpovězeny výzkumné otázky:

- 1) RGB data pořízená bezpilotními systémy jsou použitelné k detekci lesních disturbancí, primárně způsobenou lýkožroutem smrkovým.
- 2) Termální data pořízená bezpilotními systémy jsou použitelné k detekci lesních disturbancí, primárně způsobenou lýkožroutem smrkovým. Data dosahovaly vyšší přesnosti než RGB snímky.
- 3) Rozdíly mezi zdravými, napadenými a mrtvými stromy jsou markantní. Nejlépe byly detekovány mrtvé stromy.
- 4) Stromy před napadením kůrovcem vykazují vyšší teplotu než stromy napadené.

9 Přílohy

Obr. 1: Bezpilotní systém eBee Plus	8
Obr. 2: Bezpilotní systém eBee X	8
Obr. 3: Křivka spektrální odrazivosti vegetace	14
Obr. 4: Random Forest algoritmus	16
Obr. 5: Zájmové území NPR Rejvíz	23
Obr. 6: Vývoj kalamity kůrovce v NPR Rejvíz	24
Obr. 7: Rozdílová analýza napadení kůrovcem dle členění krajů	24
Obr. 8: Kůrovcová mapa 2019	25
Obr. 9: Kůrovcová mapa 2020	25
Obr. 10: Vstupní data SODA kamera sjednoceného území	26
Obr. 11: Vstupní multispektrální a termální data sjednoceného území (red-edge MX, thermoMAP)	27
Obr. 12: Kamera SODA	27
Obr. 13: Kamera RedEdge-MX	28
Obr. 14: Kamera ThermoMAP	28
Obr. 15: Sjednocené vstupní SODA orthomosaiky	29
Obr. 16: Sjednocení vstupní multispektrální a termální orthomosaiky	30
Obr. 17: Sjednocené vstupní multispektrální a termálních DSM a DTM snímky	30
Obr. 18: Zobrazení kombinace RGB a termálního snímku pomocí kombinace NIR, G, R	31
Obr. 19: Zobrazení náhodných bodů v CHM rastru	32
Obr. 20: Zobrazení bodů zdravých stromů v RGB snímku	33
Obr. 21: Zobrazení vytvořených trénovacích polygonů v CHM	33
Obr. 22: Zobrazení trénovacích dat pro RGB ortofoto snímek SODA a trénovacích dat pro termální ortofoto snímek Red edge-MX	34
Obr. 23: Zobrazení vybraného detailního území pro detekci napadených stromů	35
Obr. 24: Zobrazení vstupních ořezů detailního území	36
Obr. 25: Porovnání spektrálních křivek vybraných tříd	37
Obr. 26: Zobrazení trénovacích polygonů pro měsíc květen a červenec z RGB dat	38
Obr. 27: Zobrazení vstupních ořezů detailního území z multispektrálních dat a termálních dat ve formě false color composite	38
Obr. 28: Porovnání vytvořeného Canopy Height Modelu z RGB dat (SODA)	40
Obr. 29: Porovnání vytvořeného Canopy Height Model z multispektrálních a termálních dat	40
Obr. 30: Výsledná klasifikace časové řady sjednoceného území	41
Obr. 31: Porovnání klasifikace sjednoceného území z termálních a multispektrálních dat	42
Obr. 32: Vývoj napadení lýkožroutem v čase (RGB)	42
Obr. 33: Detekce napadených stromů lýkožroutem z multispektrální a termálních + RGB dat	43

Tabulka 1: Předešlé výzkumu detekce kůrovcové aktivity	10
Tabulka 2: Shrnutí vlnových délek použitých k nasnímání dat během tohoto výzkumu	22
Tabulka 3: Využité senzory během výzkumu	29
Tabulka 4: Vytvořená chybová matice	39
Tabulka 5: Tabulka přesností klasifikace sjednoceného území z RGB SODA senzoru	43
Tabulka 6: Tabulka přesností klasifikace sjednoceného území z kombinace termálního a RGB pásma a dále klasifikace multispektrální orthomosaiky	43
Tabulka 7: Tabulka přesností klasifikace časové řady detailního území, sloužící k detekci jednotlivých napadených stromů, z RGB SODA orthomosaiek	44
Tabulka 8: Tabulka přesností klasifikace časové řady detailního území z kombinace termálního a RGB pásma a dále klasifikace detailní multispektrální orthomosaiky sloužící k detekci jednotlivých napadených stromů	44

10 Seznam zkratek

NPR Rejvív	Národní přírodní rezervace
RGB	Red Green Blue
DPZ	Dávkový průzkum Země
UAV/UAS	Unmanned Aerial Vehicle
CES	Consumer Electronic Show
RC drony	Remote Controled drony
NIR	Near-Infrared
SWIR	Short-wave Infrared
DN	Digital Number
RF	Random Forest
SPOT	Satellite Pour l'Observation de la Terre
RMSE	Root Mean Square Error
KRNAP	Krkonošský národní park
DTM	Digital Terrain Model
DSM	Digital Surface Model
ExG	Excess of Green
NDVI	Normalizovaný diferenční vegetační index
CC	Corelation Coeficient
RGBVI	Red Green Blue Vegetation Index
JPEG	Joint Photographic Experts Group
TIFF	Tagged Image File Format
CHM	Canopy Height Model
OA	Overall Accuracy
TS	Total Samples
TCS	Total Classified Samples
KC	Kappa Coeficient
GB	Gigabite

11 Zdroje

- A Not-So-Short History of Unmanned Aerial Vehicles (UAV) - Consortiq.* (n.d.). Retrieved March 5, 2021, from <https://consortiq.com/short-history-unmanned-aerial-vehicles-uavs/>
- Agras T16 - DJI.* (2018). Retrieved March 16, 2021, from <https://www.dji.com/at/t16?site=brandsite&from=nav>
- Archimedes' principle | Description & Facts | Britannica.* (2020). Retrieved March 16, 2021, from <https://www.britannica.com/science/Archimedes-principle>
- Ashapure, A., Jung, J., Chang, A., Oh, S., Maeda, M., & Landivar, J. (2019). A Comparative Study of RGB and Multispectral Sensor-Based Cotton Canopy Cover Modelling Using Multi-Temporal UAS Data. *Remote Sensing*, 11(23), 2757. <https://doi.org/10.3390/rs11232757>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- CES: iPhone-controlled drone unveiled at tech show curtain-raiser | CES | The Guardian.* (2010). Retrieved March 15, 2021, from <https://www.theguardian.com/technology/2010/jan/06/ces-iphone-controlled-drone>
- Chlapek J., Servus M. (2019) NPR Rejvíz ve víru kůrovcové gradace – cvičení z ochrany přírody pro pokročilé, from <https://www.casopis.ochranaprirody.cz/pece-o-prirodu-a-krajinu/npr-rejviz-ve-viru-kurovcove-gradace-cviceni-z-ochrany-prirody-pro-pokrocile/>
- Deng, L., Mao, Z., Li, X., Hu, Z., Duan, F., & Yan, Y. (2018). UAV-based multispectral remote sensing for precision agriculture: A comparison between different cameras. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 124–136. <https://doi.org/10.1016/j.isprsjprs.2018.09.008>
- DJI's Drone Supremacy Comes At a Price - Bloomberg.* (2021). Retrieved March 19, 2021, from <https://www.bloomberg.com/news/features/2020-03-26/dji-s-drone-supremacy-comes-at-a-price>
- Geologické lokality – Vyhledávání - Rejvíz.* (2016). Retrieved March 19, 2021, from <http://lokalita.geology.cz/824>
- GEOTRONICS Praha. (2016). *senseFly eBee Plus | BEZPILOTNĚ.* Retrieved March 7, 2021, from https://bezpilotne.cz/sensefly-ebee-plus/?gclid=CjwKCAiAkJKCBhAyEiwAKQBCKiGU5wbUpqd-7G6f9vIJ6_tzV9OrqQDvBKj7Dq9afYIXzAmSHewJrRoCzoMQAvD_BwE

- Global Hyperspectral Imaging Spectroscopy of Agricultural-Crops & Vegetation (GHISA)*. (2014). Retrieved March 20, 2021, from https://www.usgs.gov/centers/wgsc/science/global-hyperspectral-imaging-spectroscopy-agricultural-crops-vegetation-ghisa?qt-science_center_objects=0#qt-science_center_objects
- GIS Geography (2021) Spectral Signature Cheatsheet – Spectral Bands in Remote Sensing. From <https://gisgeography.com/spectral-signature/>
- Hentati, A. I., & Fourati, L. C. (2020). Comprehensive survey of UAVs communication networks. In *Computer Standards and Interfaces* (Vol. 72, p. 103451). Elsevier B.V. <https://doi.org/10.1016/j.csi.2020.103451>
- Ing Jiří Horák, D. (2014). *Vysoká škola báňská-Technická univerzita Ostrava Hornicko-geologická fakulta DÁLKOVÝ PRŮZKUM ZEMĚ (E-learningová podpora)*.
- Ips typographus* (lýkožrout smrkový) | *BioLib.cz*. (2017). Retrieved March 19, 2021, from <https://www.biolib.cz/cz/taxon/id13972/>
- Jensen John R. (2015). Introductory digital image processing. In Remote sensing perspective.
- Krokene, P., & Liebhold, A. M. (2020). *Život s kůrovcem: Dopady, výhledy a řešení* (Issue September).
- Kuenzer, Claudia & Dech, Stefan. (2013). Thermal Infrared Remote Sensing: Sensors, Methods, Applications. 10.1007/978-94-007-6639-6.
- Kula, E. (2014). *Ochrana lesa ve střeoevropských podmínkách 1. část Lýkožrout smrkový (Ips typographus L.) kalamitní škůdce smrkových ekosystémů střední Evropy*.
- Ortenberg, Fred. (2011). Hyperspectral Sensor Characteristics. 10.1201/b11222-5.
- Lýkožrout smrkový | Kůrovcové Info. (2016). Retrieved March 11, 2021, from <https://www.kurovcoveinfo.cz/lykozrout>
- Lýkožrout smrkový Ips typographus (L.)*. (2007). Retrieved March 19, 2021, from http://www.silvarium.cz/images/letaky-los/2007/2007_lykozrout_smrkovy.pdf
- Lillesand et al. (2015). *Remote sensing and image interpretation*. Retrieved March 15, 2021
- Liu, Desheng & Xia, Fan. (2010). *Assessing object-based classification: Advantages and limitations. Remote Sensing Letters*. 1. 187-194. 10.1080/01431161003743173.
- Maloplošná zvláště chráněná území*. (2017). Retrieved March 19, 2021, from https://drusop.nature.cz/ost/chrobjekty/zchru/index.php?SHOW_ONE=1&ID=371

- Manual Surveys, RGB or Multispectral? What's the best approach for forest monitoring?* / MicaSense. (2020). Retrieved March 20, 2021, from <https://micasense.com/manual-surveys-rgb-or-multispectral-whats-the-best-approach-for-forest-monitoring/>
- Markus, W. (2014). Unmanned Aerial Vehicles. In *Max Planck Encyclopedia of Public International Law*. Oxford University Press.
<https://doi.org/10.1093/law:epil/9780199231690/e2133>
- MicaSense RedEdge-MX - senseFly*. (2019). Retrieved March 19, 2021, from <https://www.sensefly.com/camera/rededge-mx-multispectral-camera/>
- Národní přírodní rezervace Rejvíz*. (2014). Retrieved March 19, 2021, from <https://www.ochranaprirody.cz/lokality/?idlokality=371>
- Neuve-Chapelle, France Was the First Town Ever Mapped From Aerial Photos | Daily Planet | Air & Space Magazine*. (2018). Retrieved March 15, 2021, from <https://www.airspacemag.com/daily-planet/first-map-compiled-aerial-photographs-180973929/>
- Newton's Laws of Motion*. (2021). Retrieved March 16, 2021, from <https://www.grc.nasa.gov/www/k-12/airplane/newton.html>
- P4 Multispectral - DJI*. (n.d.). Retrieved March 16, 2021, from <https://www.dji.com/at/p4-multispectral>
- P4P - DJI*. (n.d.). Retrieved March 16, 2021, from <https://www.dji.com/at/phantom-4-pro>
- Prakash, A. (2000), from *International Archives of Photogrammetry and Remote Sensing*.
- Read, J. M., & Torrado, M. (2009). Remote Sensing. In *International Encyclopedia of Human Geography* (pp. 335–346). Elsevier Inc. <https://doi.org/10.1016/B978-008044910-4.00508-3>
- Ryan Firebee BQM-34A "Drone" at Combat Air Museum (2008). TOPEKA REGIONAL AIRPORT, from <https://www.combatairmuseum.org/aircraft/ryanbqm34afirebee.html>
- senseFly. (2018). *eBee X - senseFly*. Retrieved March 7, 2021, from <https://www.sensefly.com/drone/ebex-fixed-wing-drone/>
- senseFly S.O.D.A. - senseFly*. (2017). Retrieved March 19, 2021, from <https://www.sensefly.com/camera/sensefly-soda-photogrammetry-camera/>
- senseFly. (2016) *The profesional mapping drone eBee classic*
- Slonecker, T., Fisher, G. B., Aiello, D. P., & Haack, B. (2010). Visible and infrared remote imaging of hazardous waste: A review. In *Remote Sensing* (Vol. 2, Issue 11, pp. 2474–2508). Molecular Diversity Preservation International.
<https://doi.org/10.3390/rs2112474>

- Suárez, L., Berni, J. A. J., Zarco-Tejada, P. J., Suárez, L., González-Dugo, V., & Fereres, E. (2008). *Remote sensing of vegetation from UAV platforms using lightweight multispectral and thermal imaging sensors*.
<https://www.researchgate.net/publication/237138644>
- Thenkabail, Prasad. (2013). Hyperspectral remote sensing of vegetation and agricultural crops. 79.
- The RapidEye Red Edge Band*. (2012) from https://apollomapping.com/wp-content/user_uploads/2012/07/RapidEye-Red-Edge-White-Paper.pdf.
- Timeline of DJI Drones: From the Phantom 1 to the Mavic Air*. (2018). Retrieved March 15, 2021, from <https://www.drdrone.ca/blogs/drone-news-drone-help-blog/timeline-of-dji-drones>
- Trgala, M. (2019). (PDF) *MOŽNÉ PŘÍČINY A DŮSLEDKY KŮROVCOVÉ KALAMITY V LESÍCH ČR S OHLEDEM NA SPECIFIKA PŘI ZPRACOVÁNÍ KALAMITNÍHO DŘÍVÍ*. Retrieved March 5, 2021, from https://www.researchgate.net/publication/335192435_MOZNE_PRICINY_A_DUSLEDKY_KUROVCOVE_KALAMITY_V_LESICH_CR_S_OHLEDEM_NA_SPECIFIKA_PRI_ZPRACOVANI_KALAMITNIHO_DRIVI
- Tou, J. T. and R. C. Gonzalez, 1974. *Pattern Recognition Principles*, Addison-Wesley Publishing Company, Reading, Massachusetts.
- Úřad pro civilní letectví (2020). Základní informace ke změnám v regulaci dronů od 31.12.2020, from <https://www.caa.cz/news/zakladni-informace-ke-zmenam-v-regulaci-dronu-od-31-12-2020/>
- Sandwell D. *USE OF COLOR IN REMOTE SENSING*. (2004).
- Výzkumný ústav lesního hospodářství a myslivosti. (2016). *Lýkožrout smrkový | Kůrovcové Info*. Retrieved March 5, 2021, from <https://www.kurovcoveinfo.cz/skudci/lykozrout-smrkovy>
- VÚGTK Slovník VÚGTK (n.d.) Retrieved March 5, 2021 from https://www.vugtk.cz/slovník/4798_spektralne-pasmo
- Wacker A. Landgrebe D. (1972). Minimum Distance Classification in Remote Sensing, from <https://docs.lib.purdue.edu/cgi/viewcontent.cgi?article=1024&context=larstech>
- What is image classification?—ArcMap | Documentation*. (2015.). Retrieved March 20, 2021, from <https://desktop.arcgis.com/en/arcmap/latest/extensions/spatial-analyst/image-classification/what-is-image-classification-.htm>
- What is Random Forest? | IBM*. (2020). Retrieved March 20, 2021, from <https://www.ibm.com/cloud/learn/random-forest>