

Česká zemědělská univerzita v Praze

Fakulta lesnická a dřevařská

Katedra hospodářské úpravy lesů a DPZ



Česká
zemědělská
univerzita
v Praze

**Analýza materiálů DPZ pro hodnocení intenzity
lesního požáru v NP České Švýcarsko 2022**

Diplomová práce

Autor: Bc. Matyáš Berdych

Vedoucí práce: doc. Ing. Peter Surový, Ph.D.

2024

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Matyáš Berdych

Lesní inženýrství

Název práce

Analýza materiálů DPZ pro hodnocení intenzity lesního požáru v NP České Švýcarsko 2022

Název anglicky

Analysis of remote sensing materials for forest fire severity in Czech Switzerland 2022

Cíle práce

Cílem práce je zhodnocení a srovnání materiálů dálkového průzkumu Země pro odhad intenzity a síly hoření v lesním požáru v Národním parku České Švýcarsko v roce 2022.

Materiály DPZ poskytují relativně levný a podrobný zdroj informací v prostoru. Jejich využití má i své uplatnění v lesnictví pro odhad taxačních veličin, zachycení stavu abiotického nebo neabiotického narušení ekosystému.

Díky velké časové frekvenci jejich získávání je možné získávat data jak z období před požárem samotným, tak krátce po něm. Cílem práce je tedy zhodnotit, jak ve srovnání s terénním měřením tato data využít, a zároveň popsat jejich výhody a nevýhody.

Metodika

Práce bude vykonána na území Národního parku České Švýcarsko v následujících krocích.

LS 2023

- zajištění a rozbor materiálu pozemního šetření požářiště 2022

ZS 2023

- získání materiálů DPZ pro dané území, jejich analýza, popis, deskriptivní charakteristiky. Popis jejich získání, rozebrání výhod a nevýhod. Literární rešerše.

LS 2024

- statistická analýza dat, vyhodnocení přesnosti a správnosti pro jednotlivé charakteristiky pozemní inventarizace a analýza jejich korelace s materiály DPZ.

- doporučení pro praxi a výzkum.
- odevzdání práce



Doporučený rozsah práce

50-60 stran

Klíčová slova

DPZ, intenzita a síla požáru, NPČŠ

Doporučené zdroje informací

- ADÁMEK, Martin; BOBEK, Přemysl; HADINCOVÁ, Věroslava; WILD, Jan a KOPECKÝ, Martin. Forest fires within a temperate landscape: A decadal and millennial perspective from a sandstone region in Central Europe. Elsevier. 2014, s. 10.
- ADÁMEK, Martin; JANKOVSKÁ, Zuzana; HADINCOVÁ, Věroslava; KULA, Emanuel a WILD, Jan. Drivers of forest fire occurrence in the cultural landscape of Central Europe. Springer Nature. 2018, s. 15.
- ADÁMEK, Martin. Požár jako ekologický faktor v lesích střední Evropy. Autoreferát disertační práce. Praha: Univerzita Karlova v Praze, Přírodovědecká fakulta Katedra Botaniky, 2016.
- Benali, Akli, et al. "Determining fire dates and locating ignition points with satellite data." Remote Sensing 8.4 (2016): 326.
- BERČÁK, Roman et al. LESNÍ POŽÁRY V ČESKÉ REPUBLICE – CHARAKTERISTIKA, PREVENCE A HAŠENÍ: REVIEW. Zprávy lesnického výzkumu. 2018, roč. 63, č. 3, s. 11.
- Chafer, Chris J., Mark Noonan, and Eloys Macnaught. "The post-fire measurement of fire severity and intensity in the Christmas 2001 Sydney wildfires." International Journal of Wildland Fire 13.2 (2004): 227-240.
- Korpela, I.; Mehtatalo, L.; Markelin, L.; Seppanen, A.; Kangas, A. Tree species identification in aerial image data using directional reflectance signatures. Silva Fenn. 2014, 48, 1087
- Lillesand, T. M., Kiefer, R. W., Chipman, J. W. (2015). Remote Sensing and Image Interpretation. 7th ed. New York: John Wiley. ISBN 978-1-118-343-289.
- Rebecca Gibson, Tim Danaher, Warwick Hehir, Luke Collins, A remote sensing approach to mapping fire severity in south-eastern Australia using sentinel 2 and random forest, Remote Sensing of Environment, Volume 240, 2020,
- SUROVÝ, Peter, Karel KUŽELKA, Azadeh ABDOLAHNEJAD, Kateřina SIROTKOVÁ, Zlatica MELICHOVÁ a Martin SLAVÍK, 2019. Aplikace dálkového průzkumu Země v lesnictví. B.m.: ČZU v Praze, Fakulta Lesnická a Dřevařská. ISBN 8001015971.
-

Předběžný termín obhajoby

2023/24 LS – FLD

Vedoucí práce

doc. Ing. Peter Surový, PhD.

Garantující pracoviště

Katedra hospodářské úpravy lesů a DPZ

Elektronicky schváleno dne 28. 1. 2024

doc. Ing. Peter Surový, PhD.

Vedoucí katedry

Elektronicky schváleno dne 28. 1. 2024

prof. Ing. Róbert Marušák, PhD.

Děkan

V Praze dne 29. 02. 2024

Prohlašuji, že jsem diplomovou práci na téma Analýza materiálů DPZ pro hodnocení intenzity lesního požáru v NP České Švýcarsko 2022 vypracoval samostatně pod vedením doc. Ing. Petera Surového, Ph.D. a použil jen prameny, které uvádím v seznamu použitých zdrojů.

Jsem si vědom, že zveřejněním diplomové práce souhlasím s jejím zveřejněním dle zákona č. 111/1998 Sb. o vysokých školách v platném znění, a to bez ohledu na výsledek její obhajoby.

V Praze dne 5. dubna 2024

Podpis autora

Poděkování

Mé poděkování patří zejména vedoucímu mé práce doc. Ing. Petru Surovému, Ph.D. za veškerý čas věnovaný vedení a za rady a odbornou pomoc. Poděkování patří také Ing. Zlatici Melichové, která měla na starosti inventarizaci požářiště NPČŠ jejíž data byla použita v této práci.

Analýza materiálů DPZ pro hodnocení intenzity lesního požáru v NP České Švýcarsko 2022

Souhrn

Práce se zabývá analýzami materiálů dálkového průzkumu Země k analýze požáru Národního parku České Švýcarsko v roce 2022 a možnostmi tvorby matematických modelů za účelem jeho vyhodnocení. Na základě dat pozemní inventarizace požářiště byly analyzovány materiály pasivních senzorů blízkého infračerveného světla (NDVI) a materiály aktivních senzorů (LiDAR).

V první fázi byly zkoumány vzájemné vztahy indikátorů z materiálů inventarizace. Dále byly tyto hodnoty testovány korelační analýzou s NDVI před požárem, po požáru a rozdílovým NDVI, a také s daty rozdílového LiDAR. Pomocí lineární regresní analýzy a následné krokové stepwise regrese byl vytvořen model pro predikci vybraných indikátorů z materiálů inventarizace. Jako prediktory byly zvoleny některé závislé proměnné z obou datasetů DPZ, které se v předchozích analýzách ukázaly být jako zásadní. V dalším stupni analýzy byly sestaveny dva modely strojového učení: Random Forest a Support Vector Machine s cílem získat co nejpřesnější model.

Jako nejlepší model se ukázal být Support Vector Machine, který dosáhl přesnosti až 64,4 %. Nepříliš vysoké výsledky poukázaly na možné mezery v uspořádání dat, na významný vliv konkrétních přírodních podmínek zájmového území, roční době atp. Modely ale rovněž poskytují prostor pro jejich další vylepšování.

Výsledky modelů postavených na konkrétním lesním požáru ukázaly, že je stále nutné do analýz lesních požárů zahrnovat také alespoň částečnou inventarizaci, a to jak pro širší povědomí o skutečné situaci, tak pro lepší nastavení modelů pro danou situaci.

Klíčová slova: DPZ, intenzita a síla požáru, NPCŠ

Analysis of remote sensing materials for forest fire severity in Bohemian Switzerland National Park 2022

Summary

This work focuses on the analysis of remote sensing materials for examining the wildfire in the Bohemian Switzerland National Park in 2022 and the possibilities of creating mathematical models for its evaluation. Based on ground inventory data of the burnt area, materials from passive near-infrared sensors (NDVI) and active sensors (LiDAR) were analyzed.

In the initial phase, relationships between indicators from the inventory materials were examined. These values were then subjected to correlation analysis with NDVI before the fire, after the fire, the differential NDVI, and also with differential LiDAR data. Through linear regression analysis and subsequent stepwise regression, a model was created to predict selected indicators from inventory materials. Certain dependent variables from both remote sensing datasets, which were identified as crucial in previous analyses, were selected as predictors. In the next stage of analysis, two machine learning models were constructed: Random Forest and Support Vector Machine, with the goal of obtaining the most accurate model.

The Support Vector Machine emerged as the best model, achieving an accuracy of up to 64.4%. The relatively modest results highlight potential gaps in data organization, the significant impact of specific natural conditions of the area of interest, seasonality, etc. However, the models also offer room for further improvement.

The outcomes of the models based on a specific forest fire demonstrate that analyses of forest fires must still include at least a partial inventory, both for broader awareness of the actual situation and for better tuning of models for the given scenario.

Key words: Remote sensing, fire intensity and severity, Bohemian Switzerland National Park

OBSAH

1	ÚVOD.....	12
1.1.	Národní park České Švýcarsko.....	14
1.1.1.	Geologie.....	14
1.1.2.	Vodstvo.....	15
1.1.3.	Podnebí	16
1.1.4.	Lesní biotopy	16
1.2.	Mikroklimatické podmínky NPČŠ ovlivňující průběh lesního požáru	17
1.3.	Lesní požár a disturbance lesů	18
1.4.	Metody DPZ v analýze lesního požáru	19
1.4.1.	Metody DPZ v analýze požáru NPČŠ	22
2	CÍL PRÁCE.....	25
3	METODIKA.....	26
3.1.	Popis požářiště	26
3.2.	Materiál	28
3.2.1.	Inventarizace požářiště	28
3.2.2.	Inventarizované veličiny	29
3.2.3.	Data LiDAR z letadla	33
3.2.4.	Spektrální snímky RED, NIR a NDVI z letadla	34
3.3.	Statistické vyhodnocování dat	35
3.3.1.	Testování vzájemných vztahů veličin pozemní inventarizace.....	35
3.3.2.	Testování vztahu hodnot NDVI a dat pozemní inventarizace	36
3.3.3.	Testování vztahu hodnot LiDAR s NDVI a daty pozemní inventarizace.....	38
3.3.4.	Lineární regrese a Stepwise regrese.....	38
3.3.5.	Použití modelů strojového učení RF a SVM	39
4	VÝSLEDKY.....	40

4. 1.	Výsledky analýzy vzájemných vztahů veličin inventarizace	40
4. 1. 1	Korelační analýza dat pozemní inventarizace	40
4. 1. 2.	Stupně zasažení požárem podle typu lesa.....	42
4. 1. 3.	Stupně zasažení požárem podle druhu dřeviny.....	45
4. 2.	Výsledky analýzy NDVI s daty pozemní inventarizace	47
4. 2. 1.	Korelační analýza NDVI s referenčními daty inventarizace	47
4. 2. 2.	Hodnoty NDVI podle druhu dřeviny	48
4. 2. 3.	Hodnoty NDVI podle typu lesa	50
4. 3.	Výsledky analýzy LiDAR s daty inventarizace a srovnání s NDVI.....	51
4. 3. 1.	Korelační analýza LiDAR s referenčními daty inventarizace	51
4. 3. 2.	Korelační analýza LiDAR s NDVI.....	51
4. 3. 3.	Analýza vztahu severity stojících stromů s daty LiDAR.....	52
4. 3. 4.	Analýza vztahu druhu dřeviny s daty LiDAR	53
4. 4.	Výsledky vícefaktorové analýzy	55
4. 4. 1.	Vícefaktorová lineární regrese a stepwise regrese.....	55
4. 4.	Výsledky modelů strojového učení.....	58
4. 4. 1.	Výsledky modelu Random Forest (RF)	58
4. 4. 2.	Výsledky modelu Support Vector Machine (SVM)	60
5	DISKUSE	64
6	ZÁVĚR.....	70
	LITERATURA	71

SEZNAM POUŽITÝCH ZKRATEK A NÁZVŮ

1. Arc GIS pro = desktopová aplikace pro práci s GIS (viz. bod 7) od společnosti Esri
2. BK = buk
3. BO = borovice
4. DN = digitální číslo
5. DPZ = dálkový průzkum Země
6. Field maps = mobilní aplikace pro práci s GIS (viz. bod 3) od společnosti Esri
7. GIS = geografické informační systémy
8. HZS = Hasičský záchranný sbor
9. CHKO = chráněná krajinná oblast
10. LiDAR = "Light Detection and Ranging" (světelné detekční a měřicí zařízení)
11. MEAN = průměr
12. MS (Excel) = Microsoft (Excel)
13. NDVI = Normalized Difference Vegetation Index
(normalizovaný rozdílový vegetační index)
14. NIR = blízké infračervené záření
15. NPCŠ = Národní park České Švýcarsko
16. NSS = Nationalpark Sächsische Schweiz (Národní park Saské Švýcarsko)
17. RED = červené světlo
18. RF = Random Forest
19. SM = smrk
20. STD = směrodatná odchylka
21. SVM = Support Vector Machine

1 ÚVOD

Dne 24. července 2022 vypukl v Národním parku České Švýcarsko největší lesní požár v novodobé historii Českých zemí, který vznikl v důsledku jeho úmyslného založení žhářem. Ohnisko požáru se nacházelo přibližně 150 metrů nad silnicí v oblasti Malinový důl. Během hašení požáru, ke kterému byla pozvána i mezinárodní pomoc, bylo použito přes 400 ks hasební techniky, použito 10 km hadic a nasazeno přes 6 300 hasičů. Celková plocha zasažená požárem čítala více jak 1100 ha a požár se šířil i na saské území. Rok 2022 byl ale zároveň rokem v němž se odehrál největší počet lesních požárů za uplynulých 10 let. (Statistická ročenka HZS ČR, 2022)

Na území NP České Švýcarsko se však odehrávají drobnější lesní požáry běžně (tak jako i jinde). V rozmezí let 1982–2014 se odehrálo průměrně 2,7 požáru za rok o průměrné rozloze 0,5 ha. Nutno však dodat, že tato hodnota je ovlivněna velkým požárem na Havraní skále (2006), který měl rozlohu 17,92 ha. Území obou národních parků (českého a saského) má bohatou požárovou minulost, o čemž svědčí analýzy mikroskopických uhlíků a zuhelnatělého dřeva na vybraných lokalitách. Zuhelnatělé dřevo je obsaženo v půdních profilech a pomocí izotopu ^{14}C lze datovat jednotlivé částičky. Doposud jsou lesní požáry v této oblasti zmapovány po celý holocén (11 500 let) a okrajově také glaciál (ca. 14 000 let). Zdánlivě nerelevantní data však umožňují vymezit historické rozpětí variability lesních požárů (koncept Historical Range of Variability), a tedy stanovit hranice přijatelných změn složek ekosystémů a ekologických procesů. Slouží také k identifikaci hlavních faktorů lesních požárů a usnadňuje hodnocení jejich dlouhodobé interakce. (Bobek et al. 2022)

Výsledky jiné studie ukázaly, že lesní požáry v NPCŠ se vyskytovaly na podobných lokalitách již od Subatlantiku. Jedná se o lokality jako vyvýšené skalní plošiny a jihozápadní svahy. Na těchto lokalitách jsou dnes polopřirozené porosty borovice lesní (*Pinus silvestris*). (Adámek, 2016)

Lesní požár vyvolal v české společnosti vlnu kritiky na stranu lesníků a lesnictví ale také otázky ohledně změny klimatu a případné častější jevy tohoto typu i u nás. Laická i část odborné veřejnosti kritizovala v kontextu lesního požáru v Českém Švýcarsku především velkou míru mrtvého dřeva v lese, které zvyšuje podíl hořlavého materiálu a činí tak požár nebezpečnějším a ohrožujícím soukromý majetek lidí. Na

prvním místě je však zapotřebí si uvědomit, že zvýšený podíl mrtvého dřeva v lese je nejen žádoucí z pohledu ekologického a z pohledu přírodě blízkého způsobu pěstování lesů (a je zakotven v zákoně 289/1995), ale je také charakteristický právě pro lesy národních parků, které se snaží přírodní procesy vč. přítomnosti mrtvého dřeva co nejvíce podporovat.

K otázce lesních požárů v přírodních podmínkách Českých zemí stojí za vysvětlení, že mnohé oblasti severoamerického temperátního regionu mají obdobné přírodní podmínky. Přesto jsou v těchto severoamerických oblastech lesní požáry běžnou součástí cyklu lesa. Nízký výskyt lesních požárů u nás je zapříčiněn spíše lesnicko-ekologickou tradicí (nikoliv klimatem), kdy hospodaříme v relativně malých porostech na hustě obydleném území, zatímco v severní Americe je hustota obydlení nízká a porosty jsou mnohem větší a méně členité. (Adámek, 2016)

Velmi významným faktorem intenzity požáru jsou však specifické přírodní podmínky v oblasti jako je podloží, reliéf terénu, který má vliv na proudění větrů, expozice, zapojení porostu, druhová skladba nebo půda. (Berčák et al. 2018) Faktorem příčiny vzniku lesního požáru v našich podmínkách je nejčastěji selhání lidského faktoru: nedopalek, nedohašený oheň tábořiště, vzplanutí porostu od pálení klestu apod. Příčiny požáru úderem blesku aj. jsou spíš okrajové. (Adámek et al., 2014) I proto, že nejčastější příčinou vzniku lesních požárů je lidské zavinění, zakazuje lesní zákon č. 289/1995 kouření v lese nebo roždělávání otevřeného ohně blíže než 50 m od okraje porostu. Zákon 133/1985 pak řeší dokonce prevenci vzniku požáru. Státní podnik Lesy České republiky se řídí interními pravidly pro pálení klestu v lesním porostu. To je zakázáno provádět od 1. dubna až do konce října, kdy je výskyt lesních požárů největší. Dále je pálení klestu ošetřeno pravidly nejmenší vzdálenosti do jehličnatých porostů atd. (Berčák et al, 2018)

S ohledem na časté zavinění požáru člověkem je také potřeba zmínit, že právě národní parky do velké míry fungují na turismu a v chráněných oblastech se tak nachází paradoxně velká koncentrace lidí včetně těch, kteří porušují zákazy vstupu mimo vyznačené trasy. Existuje zákonná možnost znepřístupnění lesa na základě rozhodnutí státní správy lesů na dobu určitou, což v extrémně suchých měsících napomáhá k omezení případného počtu událostí iniciace hoření. (Berčák et al, 2018) Zásadní je

však v otázce vzniku a rozsahu lesních požárů u nás kombinace lidského zavinění s konkrétními přírodními podmínkami a počasím. (Adámek et al., 2018)

1. 1. Národní park České Švýcarsko

Národní park České Švýcarsko je nejmladším národním parkem v České republice. Byl založen 1. ledna 2000 zákonem č. 161/1999. Jeho současná rozloha činí 7 933 ha. Lesy národního parku čítají 7 621 ha plochy, což činí 96,1 % celkové rozlohy parku a jedná se tak o nejlesnatější národní park v České republice. NPČŠ sousedí s Národním parkem Saské Švýcarsko (Nationalpark Sächsische Schweiz), který leží ve Svobodném státě Sasko, a který byl založen o deset let dříve.

Národní park byl založen především kvůli ochraně specifických Labských pískovců a sní souvisejícím specifickým rázem krajiny, dále kvůli ochraně živočichů a původních rostlin. Součástí NPČŠ je i CHKO Labské pískovce. (Ondrušková, 2023, NPČŠ, 2024)


1. 1. 1. Geologie

Po NPČŠ jsou typické tzv. Labské pískovce, které se rozprostírají na území Čech i Saska, tedy na území obou zmíněných národních parků. Celková plocha Labských pískovců je cca 700 km². Jedná se o Českou křídovou pánev charakteristickou specifickými kvádrovými útvary pískovcových skal (tzv. křemenné pískovce) a na ně vázanými ekologickými podmínkami, které určují zdejší biodiverzitu.

Nejstaršími horninami jsou zde brtnická a rumburská žula náležící do Lužického masívu staré asi 700 milionů let. Typické pískovce jsou staré asi 90 milionů let a náleží do svrchnokřídového moře (druhoohory). Asi 1000 m silná vrstva pískovce, která tvořila někdejší mořské dno dále obsahuje i prachovce a slepence. Střední část je tvořena cca 400 m silnou vrstvou křemenných pískovců (jizerské souvrství), které pokrývají většinu dnešního území NP. Starší pískovcové vrstvy tzv. bělohorského souvrství jsou viditelné jen v hluboce zaříznutém údolí říčky Kamenice.

Třetihorními útvary (65 až 2 miliony let) jsou tvořeny výplněmi bočních magmatických kanálů, které byly odhaleny až po odnosu nadložních sedimentů.

Magmatické horniny jsou zde tvořeny především čedičem a znělcem. Na vrcholu některých čedičových kopců jsou výchozy s charakteristickým šestibokým výchozem (lidově „varhany“).



Obrázek 1: Geologický profil NPČŠ a NSS (NPČŠ, 2024)

Dnešní charakter krajiny je utvořen v důsledku tzv. Alpinského vrásnění a odnosu materiálu hlubokou říční erozí. Výška většiny vrcholů v NP je v rozmezí 450 až 480 metrů nad mořem. Naopak ale kóta 114 m n. m. v Hřensku je nejnižším bodem v ČR. Nejvyšším bodem NP je pak Růžovský vrch s výškou 619 m n. m., který je zároveň jedinou stolovou horou Labským pískovců. (NPČŠ, 2024)

1. 1. 2. Vodstvo

NPČŠ je bohatý na vodní toky i podzemní vodu. Hlavním vodním tokem je řeka Labe, dále říčka Kamenice s přítoky. Řeka Labe je typická tím, že odvodňuje většinu území Českosaského Švýcarska a náleží do úvodí Baltského moře. Labe vytváří až 300 m hluboké kaňony vzniklé říční erozí. Díky tomu byla odkryta řada starých hornin v podloží.

Mezi stojaté vody NP patří např. Olešský rybník, Ostrovský rybník, Královomlýnský rybník a další menší vodní nádrže.

Území NP je bohaté na podzemní vody, a to především díky dobře propustným křemenným pískovcům mnohasetmetrovou mocností. Drenážemi podzemních vod jsou zde hluboko zaříznuté toky Kamenice, Křinice a Labe. (NPČŠ, 2024)

1. 1. 3. Podnebí

Klimatické podmínky v NPČŠ jsou velmi odlišné na každé lokalitě. Nejteplejšími oblastmi parku jsou Růžovská plošina, Děčínská kotlina a jižní okraj CHKO Labské pískovce. Naopak hluboké roklemi Jetřichovických stěn jsou typické dlouho trávající zimy, resp. sněhovou pokrývkou hluboko do jara. Pro tuto oblast je typická tzv. klimatická inverze. Teplotní rozdíly v parku odpovídají převýšení až 600 m. Například v centrální části NP se průměrná teplota pohybuje okolo 7°C ale v Děčíně okolo 9°C.

Srážky v NP představují největší rozdíly. Např. Děčín má průměrné srážky 673 mm, Jetřichovické stěny 800 mm a sousední Lužické hory dokonce 1000 mm. Říčka Kamenice je zde nejvíce náchylná na přívalové deště a s nimi souvisejícími bleskovými povodněmi. (NPČŠ, 2024)

1. 1. 4. Lesní biotopy

Nejlesnatější národní park v ČR (přes 95 % lesů) je silně ovlivněn hospodářským využíváním lesů v minulosti. Smrk zde zaujímá skoro 60 % lesů oproti přirozenému zastoupení 5,2 % (viz obrázek 4). Zachovaly se zde zbytky původních lesů, a to především na těžko dostupných lokalitách, tj. na skalních vrcholech, prudkých svazích, v hluboce zaříznutých roklich. Nachází se zde reliktní bory či původní ekotyp smrku ztepilého. Dále jsou zde zbytky původních bučin, teplomilných doubrav a lužních lesů. (NPČŠ, 2024)

Lužní lesy jsou tvořeny především vrbo-topolovými luhy, které tvoří vrba bílá (*Salix alba*), vrba křehká (*S. fragilis*), v. košíkářská (*S. viminalis*), topol černý (*Populus nigra*). Dále jsou zde vzácnější jasan-olšové luhy, smrkové olšiny a prameništění jaseniny. (NPČŠ, 2024)

Dubohabřiny jsou vázané na teplejší lokality parku a na bohatší půdy jižní část parku. Kyselá doubravy jsou vázané na chudší stanoviště na skalních plošinách či

v kaňonu Labe. Tvořeny jsou dubem zimním (*Quercus petraea*), dubem letním (*Q. robur*) a borovicí lesní (*Pinus silvestris*). (NPČŠ, 2024)

Suťové lesy jsou tvořeny lípou srdčitou (*Tilia cordata*), habrem obecným (*Carpinus betulus*), javorem babykou (*Acer campestre*), javorem klenem (*A. pseudoplatanus*), jilmem drsným (*Ulmus glabra*) a jasanem ztepilým (*Fraxinus excelsior*). Vzácně jsou zde i roklínové lesy. (NPČŠ, 2024)

Květnaté bučiny, ačkoliv mají zanedbatelnou rozlohu, výrazně zlepšují biodiverzitu parku. Kyselé bučiny v historii zabíraly největší rozlohu dnešních Labských pískovců. Jednalo se o tzv. bikové bučiny. Dalšími typickými dřevinami byl buk lesní (*Fagus sylvatica*), javor klen (*A. pseudoplatanus*), smrk ztepilý (*Picea abies*) a dnes vzácná jedle bělokorá (*Abies alba*). Zdejší bučiny tvoří nejnižší položené bučiny v ČR. (NPČŠ, 2024)

Nepříliš rozsáhlé, ale přesto významné, jsou zdejší reliktní rašelinné bory tvořené borovicí lesní (*Pinus silvestris*), bžizou bělokorou (*Betula pendula*) a jeřábem ptačím (*Sorbus aucuparia*). Suché bory se nachází na osluněných lokalitách s jižní expozicí. Vlhké bory naopak na stinných lokalitách. (NPČŠ, 2024)

Přirozené smrčiny tvořené smrkem ztepilým (*Picea abies*) se vyskytovaly (a dodnes částečně vyskytují) v inverzních roklích, a to jako součást kyselých bučin nebo jako podmáčené smrčiny. (NPČŠ, 2024)

Kulturní lesy tvoří většinu lesních porostů v NPČŠ. Tyto kulturní či hospodářské lesy byly zakládány v lokalitách s nízkou druhovou rozmanitostí, takže druhově bohatší lokality většinou zůstaly zachovány. Hospodářské lesy jsou zde tvořeny především smrčinami a bory. Dále se zde nachází dřeviny jako modřín opadavý (*Larix decidua*), dub červený (*Quercus rubra*), douglaska tisolistá (*Pseudotsuga menziesii*), jírovec maďal (*Aesculus hippocastanum*) nebo kaštanovník setý (*Castanea sativa*). (NPČŠ, 2024)

1. 2. Mikroklimatické podmínky NPČŠ ovlivňující průběh lesního požáru

Teplotní a vlhkostní veličiny v porostu se mohou lišit od obecných meteorologických údajů pro danou oblast. Je to dáno konkrétní situací v lokalitě, kterou ovlivňuje morfologie terénu, expozice, hloubka půdního pokryvu, zápoj porostu atd. Pro

NP České Švýcarsko je charakteristické nadměrné množství mrtvého dřeva v podobě stojících suchých smrků. Akademie věd ČR ve spolupráci se Správou Národního parku sleduje dlouhodobě mikroklima přímo v porostech, a to od 0 do 15 cm nad povrchem. Díky údajům z roku 2021 je zřejmé, že teploty v zapojeném živém porostu jsou nižší než v mrtvém lese. To je způsobeno absencí korunového zápoje, a tedy větším prouděním slunečního záření dovnitř porostu a zahříváním povrchu, čím také dochází k většímu prosychání půdy. Nejnižší vlhkost humusové vrstvy byla naměřena v živých smrkových porostech, vyšší na holinách a nejvyšší vlhkost byla paradoxně v mrtvých smrkových porostech. Z uvedeného vyplývá, že pro povrchový požár jsou nejvíce vhodné holiny a mrtvé porosty, na nichž snadněji prosychá palivo. Naopak podpovrchový požár zde měl lepší podmínky v živém smrkovém lese, kde je většina půdní vlhkosti odsátá stromy ze země. (Bobek et al, 2022) Mezi další faktory ovlivňující hoření nebo frekvenci požárů je i geologická charakteristika prostředí. Pro NPČŠ jsou typické pískovce, které, jak se ukazuje, jsou nápadně často postihovány lesními požáry (Adámek, 2016)

1. 3. Lesní požár a disturbance lesů

Lesy trpí různými disturbancemi. Pojem disturbance znamená narušení. V případě disturbance lesů pak hovoříme o narušení zápoje, které má vliv na destabilizaci lesního porostu. Kromě narušení zápoje se dále jedná o rozpad stářím či odumírání stromů ve velkém počtu. Mezi nejznámější disturbance patří poškození silným větrem (polomy), sněhem (narušení korun a zlomy), záplavami (odumírání) a ohněm (lesní požáry). Disturbance rozdělujeme na maloplošné, středně silné a velkoplošné. Působením disturbancí vzniká mnoho nových biotopů, které označujeme jako biologické dědictví. Může se jednat o zbytky mrtvého dřeva ve formě stojících kmenů či ojediněle stojící staré stromy ponechané k rozpadu, které jsou domovem některých živočišných druhů (Kjučukov et al., 2024). Jak už bylo řečeno, mezi disturbance patří i lesní požár, jehož analýzou se zabývá tato práce, a to na lesním požáru Národního parku České Švýcarsko, který řadíme mezi velkoplošné disturbance.

Lesní požár je požár lesního porostu, který můžeme rozdělit na požár korunový (požár dosáhl výšky porostu), požár povrchový (hoří hrabanka, opad, traviny a další nízké rostliny) a požár podpovrchový. (Berčák et al., 2018) Vedle přirozených příčin

vzniku hoření (např. blesk) je nejčastější příčinou vzniku lesního požáru lidské zavinění. (Adámek, 2016) V letech 2006–2010 bylo v Evropě 97 % lesních požárů s vyšetřenou příčinou vzniku zaviněno člověkem. (Adámek et al., 2018). V České republice bylo v rozmezí let 2006–2015 zaznamenáno 7255 lesních požárů z nichž 2438 (33,6 %) bylo způsobeno zápalkou či cigaretovým nedopalkem. Jen u 96 případů (1,32 %) byl příčinou atmosférický výboj. (Berčák et al., 2018)

Lesní požár má svou charakteristiku a anatomii. Tu tvoří ohnisko, čelo, týl a pásy. Může mít ale také body a ostrovy. Ohnisko označuje místo iniciace hoření. Čelo požáru je poháněno směrem větru a způsobuje největší škody. Týl požáru je naopak na straně proudění větru. Jedná se o místo s pomalejším průběhem a je snáze uhasitelné. Křídla požáru jsou boční strany hořící plochy, prsty pak úzké pásy, které vybočují z hlavní plochy hoření. Ostrov je místo v požářišti, které požár obešel. Naopak bod požáru je místo mimo hlavní požářiště, který vznikl odletujícími jiskrami či uhlíky. (Berčák et al., 2018)

Dále rozdělujeme požár do pásem: Pásmo hoření je pásmo kde se v důsledku vysoké teploty uvolňují plyny, které nadále živí oheň. Pásmo přípravy je území nacházející se nejbliže pásmu hoření. Dochází zde k zahřívání hořlavých materiálů. Pásmo zadýmení je pohyblivé pásmo, kde dochází k pohybu dýmu a páry vzniklých hořením a rozkládáním hořlavých látek.

1. 4. Metody DPZ v analýze lesního požáru

Současná doba nabízí řadu inovativních řešení pro práci s daty o lesních porostech. Pro vyhodnocování zdravotního stavu lesa, zásoby nebo požáru lze využívat data dálkového průzkumu Země (DPZ), konkrétně fotografické snímky z letadel, dronů, helikoptér nebo družic či data laserového skenování prostoru. (Surový et al., 2020) Konkrétní metoda a technologie pak záleží na předmětu našeho poznávání.

Pro hodnocení lesního porostu a jeho zdravotního stavu je možné využít tyto technologie, které jsou finančně i časově mnohem přívětivější oproti pozemní inventarizaci. (Surový et al., 2020) Například velmi častá metoda NDVI snímků (Normalized difference vegetation index – normalizovaný rozdílový vegetační index) založená na principu vysílání blízkého infračerveného světla je velice přesná a dnes

nejpoužívanější metoda vyhodnocování zdravotního stavu vegetace a lesních porostů z dat DPZ. Základem pro výpočet indexu vegetace NDVI jsou multispektrální a hyperspektrální snímky. Multispektrální snímky využívají jenom 3-10 pásem o šířce 50-100 nm. Hyperspektrální snímky využívají ale až stovky pásem o užší šířce (2-10 nm) a poskytují detailnější informace o stavu.

Do 70. let 20. století se pořizovaly snímky na film. Později bylo zavedené již digitální snímkování povrchu Země. Nejmenší vyhodnocovanou jednotkou snímku je pixel. Každý pixel je zaznamenáván určitým počtem bitů. Přesnost elektromagnetického záření je definována radiometrickým rozlišením. Čím vyšší počet bitů, tím více detailů snímek obsahuje. 1 bit představuje dvě úrovně intenzity záření (0 a 1), 2 bity mají čtyři úrovně atd. Počet úrovní představuje rozlišení stupňů šedi. Většina takových snímků má 8 bitů, což představuje 0-255 úrovní šedé, 11 bitů 0-2047 úrovní šedé, 12 bitů 0-4095 úrovní šedé a 16 bitů 0-65535 úrovní šedé. Jedná se o počet úrovní šedé v jednom pásmu, který je definován digitálními čísly (DN) (Surový et al., 2020) Počet úrovní šedi se vypočítá jako: $2^8 = 256$, $2^9 = 512$, $2^{10} = 1024$, $2^{11} = 2048$ a $2^{12} = 4096$ atd. (Lillesand et al., 2015)

U multispektrálních snímků je každý pixel definován digitálním číslem (digital number – DN) představující stupeň šedi. Barevné spektrum snímku je tvořeno třemi základními barvami: červenou modrou a zelenou. (Lillesand et al, 2015) Družice snímající spektrální pásma mají multispektrální senzory a jsou schopny zachycovat snímky ve velkých vlnových délkách. Snímky pokrývají infračervené (IR) záření, krátké vlny i tepelné vlnové délky. Hyperspektrální senzory mají naopak úzký vlnový rozsah v jednotlivých pásmech a pokrývají obvykle viditelné, krátké a NIR vlnové délky. Panchromatické senzory pořizují snímky jen jednoho spektrálního pásma, které mají vysoké prostorové rozlišení. Digitální číslo (DN) každého pixelu určuje intenzitu slunečního záření, které se odráží od snímaných objektů (například vegetace). Tyto snímky s širokým rozsahem vlnových délek, které se zobracují na stupních šedi, pokrývají viditelné NIR vlnové délky. (Surový et al., 2020)

Prostorové rozlišení družicového snímku spočívá ve schopnosti rozpoznat objekty a jejich části na povrchu Země. Čím menší pixel máme, tím přesnější data můžeme získávat. Spektrální rozlišení je pak schopnost senzoru rozlišovat vlnové délky v odrazivosti záření od objektů na povrchu. (Surový et al., 2020)

Snímané objekty lze posuzovat podle odrazivosti jednotlivých spekter. Při materiálech s velmi podobnou odrazivostí je hlavním ukazatelem rozdílu vlnová délka infračerveného záření (NIR), která je používána k hodnocení objektů za pomoci vegetačních indexů. Právě NIR je základem normalizovaného diferenčního vegetačního indexu NDVI, protože vykazuje největší citlivost v odrazu od objektů (v našem případě např. zdravotní stav různých listů nebo jehličí stromů). Absolutní hodnota indexu NDVI je velmi signifikantní v hodnocení zdravotního stavu vegetace. Hodnoty indexu se pohybují od -1 do +1 kde záporné hodnoty představují většinou vodu, hodnoty kolem 0 sníh, nízké kladné hodnoty traviny a keře a vyšší kladné lesy. Podle zdravotního stavu dané rostliny se liší odrazivost NIR záření (blízkého infračerveného) a RED (červené oblasti světla). Vypočítává se podle následujícího vzorce: $NDVI = \frac{NIR-RED}{NIR+RED}$. Na podobném principu lze vypočítat jiné indexy, které pracují s jinými spektry záření. (Surový et al., 2020)

Mezi nejznámější družice poskytující tyto materiály patří Sentinel-2 z projektu Copernicus, americká Landsat, WorldView 1&2, SPOT-5 atd. Tyto družice zachycují jednotlivá místa v různých frekvencích a v různém prostorovém rozlišení. Například Landsat 15-60 m v intervalu 16 dnů, SPOT-5 2,5-10 m v intervalu 2-3 dnů atd. Díky tomu je možné v čase sledovat změny na zemském povrchu nebo stav vegetace či zdravotní stav lesů. (Surový et al., 2020)

Jednou ze studií zabývajících se monitoringem lesních požárů byla i studie na základě dat z modulu MODIS (satelit Terra a Aqua od NASA Earth Observing System – EOS), která se zabývala vznikem velkých požárů v regionech po celém světě: např. Aljašce, Portugalsku, Řecku, Kalifornii nebo jihovýchodní Austrálii. Mapovala místa vzniku a místa zániku velkých požárů. Cílem studie bylo vyhodnocení přesnosti satelitních dat v porovnání s databází o lesních požárech. Výsledkem studie bylo potvrzení přesnosti satelitních dat. (Benali et al., 2016)

Jiná studie se zabývala již blíže hodnocením lesních požárů v jihovýchodní Austrálii, kde byly použity snímky z družice Sentinel-2 a vyhodnocení mělo vysokou přesnost. Podle míry zasaženosti lokality požárem se pohybovala od 70 % do 95 %. (Gibson et al, 2020) Podobně je možné využít multispektrální snímky k určování druhů dřevin. Při analýze jsou použity smíšené efekty modelování k prozkoumání druhově specifických variací a kovariací v reálných odrazových datech světelného záření. Napřič

tomu, že byly použity směrové signatury ke klasifikaci dřevin, nepřinesla tato metoda zlepšení v přesnosti výsledků. (Korpela et al., 2014)

Pro účely této práce nás zajímá především stratifikace dat, kdy dochází k rozvrstvení velkých ploch (například požářiště NP České Švýcarsko) a nalezení více podobných či stejných ploch v rámci oblasti. Díky rozvrstvení je možné vytvořit efektivnější vzorkovací plochy a vytvořit relativně přesnou alternativu pozemní inventarizace v závislosti na nákladech a času. Podobně jsou optická družicová data využívána k hodnocení lesních parametrů jako je výška stromů, tloušťka kmene, porostní zásoba atd. Jedním z takových parametrů je i množství uhlíku. Základem práce se satelitními daty ve vyhodnocování zdravotního stavu porostu je především využití dat před a po. (Surový et al., 2020) V případě této práce, která se zabývá vyhodnocováním intenzity lesního požáru v NP České Švýcarsko je zásadní porovnání stejného typu snímků před a po požáru a jejich vyhodnocení. Jediným rozdílem je, že snímky použité pro tuto práci jsou pořízené z letadla, nikoliv z družice. Princip však zůstává stejný.

Pro představu o vyhodnocování následků lesního požáru můžeme použít data z lesního požáru v Sydney v roce 2001. 225 000 ha velká oblast zasažení byla nejprve ohodnocena pomocí hodnotící příručky na 342 zkusných plochách. Intenzita požáru byla klasifikována podle stavu vegetace a dalších znaků požáru. Všechny 342 ploch bylo vyhodnoceno s 88 % přesností. Následně byla použita data družice SPOT-2, a to jak snímky před požárem, tak po něm. Výsledky analýzy satelitních snímků v porovnání s pozemním měřením byly ve shodě na 88 %. Koeficient Kappa byl 0,86, což naznačuje vysokou míru shody. Studie tak potvrdila přesnost v odhadu poškození požárem a zároveň i vyvrátila některé tradiční názory na vliv morfologie terénu a sklon svahu vůči šíření požáru, protože v některých situacích působil např. vliv sklonu svahu obráceně. (Chafer et al., 2004)

1. 4. 1. Metody DPZ v analýze požáru NPČŠ

Z předchozích informací vyplývá, že nejvhodnějšími metodami pro posuzování stavu lesních porostů a porostních veličin jsou metody hodnocení multispektrálních a hyperspektrálních snímků pořízených satelitem, letadlem nebo dronem. Tyto snímky řadíme mezi tzv. pasivní senzory a mají různou přesnost. Multispektrální snímky kombinují tři kanály viditelného světla (červené, zelené a modré) s blízkými kanály

infracherveného záření. Z těchto dat je možné odhadnout vitalitu vegetace. Hyperspektrální snímky jsou podrobnější. Obraz jsou schopny zaznamenávat až na několika stovkách kanálů. Dále jsou to materiály poskytující informace o prostorovém uspořádání pořízené tzv. aktivními senzory kam řadíme digitální model povrchu, digitální model terénu či laserové skeny. Ty dokáží pomocí až milionkrát opakovaného vysílání velmi přesného paprsku zmapovat s vysokou přesností pevná tělesa v okolí a vytvořit tzv. bodové mračno. V posledních desetiletích je pro nosiče senzorů možné využívat také bezpilotní letadla a drony. Díky schopnosti dronu libovolně omezit rychlost letu až na „nulu“, a také díky větší blízkosti k povrchu, je možné pořizovat snímky s nejvyšší přesností, a to až do úrovně jednotlivých listů (Surový et al., 2019). Obecně tedy platí, že čím blíže povrchu data zaznamenáváme, tím vyšší je přesnost, ale také i delší doba pořízení materiálů na určitou plochu (Surový et al., 2019, Gibson et al., 2020).



Obrázek 2: Druhy nosičů se vztahem k rozsahu zkoumaného území, rychlosti a přesnosti měření (Ondrušková, 2023)

Pro hodnocení intenzity lesního požáru v NPČŠ tedy byly použity materiály DPZ na vyšší úrovni přesnosti při zohlednění, že se jedná o velice rozsáhlou plochu (1100 ha), pro kterou by nebylo snadné pořídit tak jednoduše materiály DPZ např. z dronu. Použitými materiály pro tuto práci jsou hyperspektrální snímky pasivních senzorů z letadla a digitální model povrchu, tzv. LiDAR pořízený rovněž z letadla.

Přesnost odhadu poškození požárem bude stanovena podle referenčních údajů pozemní inventarizace, kterou považujeme za nejpřesnější. Jedná se o podobný postup jako v uvedených studiích Chafer et al. (2004) z Austrálie, kde však byly data pozemní inventarizace porovnávány s daty DPZ z družice. V případě této práce se jedná o data s vyšším rozlišením, která mají za cíl posloužit jako materiál pro analýzu intenzity požáru v celkem složitém prostředí. NP České Švýcarsko je, jak již bylo uvedeno, velice členitý a nachází se zde na malé ploše i velká výšková převýšení, lužní lesy, ale i rozlehlé skalní masivy. Z hlediska analýzy dat DPZ je tak výzvou správně hodnotit stav porostu do něhož na povrchu vstupují zcela jiné a nežádoucí prvky.

2 CÍL PRÁCE


Cílem této práce je zhodnocení a srovnání materiálů DPZ (dálkového průzkumu Země) pro odhad intenzity a síly hoření v lesním požáru v Národním parku České Švýcarsko.

Pro analýzu dat DPZ byly k dispozici dvě sady dat: spektrální snímky NIR pořízené z letadla pasivními senzory. Díky nim je možné vypočítat index NDVI před událostí a po události, a z obou hodnot následně spočítat rozdílový NDVI index, který představuje velikost změny indexu NDVI po požáru. Dále LiDAR data získaná aktivními senzory pro posouzení prostorové změny. Ta se týká především detekce korun nebo stojících stromů. Zjednodušeně to znamená, že pokud někde došlo k pádu stromů, LiDAR zaznamená změnu v modelu povrchu z čehož lze vyvozovat, že na takovém místě byla intenzita lesního požáru vysoká. Výsledná analýza těchto dat v různých kombinacích by měla zjistit, které veličiny jsou na sobě nejvíce závislé a do jaké míry jsou modely odvozené z dat DPZ použitelné namísto časově a logisticky náročné pozemní inventarizace či jsou použitelná v kombinaci s ní. V případě daleko větších požárů, co do plošného rozsahu, už prakticky není možné realizovat kompletní pozemní inventarizaci a modely na základě DPZ tedy budou nezbytné.

Vedle již zmíněných přírodních podmínek NPČŠ je na místě zdůraznit především pro lesní požár relevantní údaje, které se týkají zájmového území (tj. ploše požáru). NPČŠ je z lesnického hlediska zajímavý především lesnatostí. Ta zde činí přes 95 % území Národního parku. Zdejší flora je ovlivněna podložím a členitostí terénu. Podloží je většinou chudší, písčivcové. Jen místy se nachází na živiny bohatší horniny jako znělec, slínovec, čedič nebo vápenec.

Lesy, které jsou předmětem této práce jsou zde ve složení, které neodpovídá přirozenému zastoupení dřevin. To je dáno především hospodářskou minulostí této oblasti, která sem přinesla jako hlavní hospodářskou dřevinu smrk ztepilý (*Picea abies*). Pozůstatky původních lesů jsou v hluboko zaříznutých roklích, kde se také nachází původní ekotyp smrku ztepilého, dále na nepřístupných skalních vrcholech. Nachází se zde také pozůstatky listnatých lesů, a to především bučin, dále teplomilné doubravy a na vodní toky vázané lužní lesy. (NPČŠ, 2024)

Porovnání druhové skladby lesů Národního parku České Švýcarsko v minulosti a v současnosti



Obrázek 4: Porovnání přirozené a současné druhové skladby v NPČŠ (NPČŠ, 2024)

Z pohledu velkého požáru v NPČŠ v roce 2022 jsou ale relevantní především velké smrkové a případně borové monokultury, které, tak jako jinde, byly silně

ohroženy suchem a nastupující klimatickou změnou, a v důsledku toho také silně zasaženy kůrovcovou kalamitou. V souladu s péčí o území národních parků jsou odumřelé porosty ponechávány přirozenému rozpadu. Právě množství suchého mrtvého dřeva většinou jehličnatých dřevin (smrk) a absence korunového zápoje byly velice zásadní pro šíření a intenzitu tak velkého lesního požáru, jaký se udál v roce 2022.

3. 2. Materiál

3. 2. 1. Inventarizace požářiště

V termínu od října 2022 do dubna 2023 provedla Česká zemědělská univerzita v Praze ve spolupráci se správou Národního parku České Švýcarsko inventarizaci kompletní plochy požářiště na českém území. Inventarizace v terénu se účastnilo přibližně 14 osob, mezi nimiž byli doktorandi i vedoucí Katedry hospodářské úpravy lesů a DPZ, studenti vč. autora této práce a další. Práce probíhaly především za lepšího počasí, neboť sníh v zimních měsících neumožňoval měření hodnot na zkusných plochách a povrch země byl v dešti a sněhu velmi kluzký a nebezpečný pro pohyb. Cílem bylo naměření hodnot na všech zkusných plochách, které byly uspořádány schematicky 100 m vzdálené od sebe bez ohledu na přístupnost terénu. Některé body tak byly nepřístupné nebo přístupné za velmi riskantních podmínek, a proto nebyly navštíveny. Jiné plochy, které byly na základě satelitních snímků vyhodnoceny jako shořelé, byly po fyzické návštěvě shledány netknutými požárem a hodnoty zde odečítány nebyly. Kromě odečítání hodnot jako je míra ohoření stromů nebo hrabanky, byla také každá plocha fotografována 3D kamerou (virtuální prohlídka) pro dokumentaci plochy a možnost porovnání stavu ploch v budoucnosti.

Během práce v terénu působily největší potíže digitální zařízení jako je mobilní telefon a kamera propojená s mobilní aplikací pomocí Wi-Fi. Mobilní signál se totiž ve skalách ztrácel v závislosti na expozici a ztráta signálu znesnadňovala zapisování dat a pořizování snímků kamerou. Rovněž GPS signál se v členitém terénu ztrácel a nebylo vždy možné přesně zaměřit v terénu konkrétní bod, protože označení polohy se v aplikaci neustále pohybovalo. Proto se muselo na signál čekat delší dobu. Samotná pochůzka po požářišti se velmi často odehrávala alespoň ve dvojicích, protože množství náčiní a kooperace při měření zkusné plochy, zamření severu, zapisování a odečítání hodnot vyžadovaly aspoň čtyři ruce. V některých případech měřili i jednotlivci a zřídka

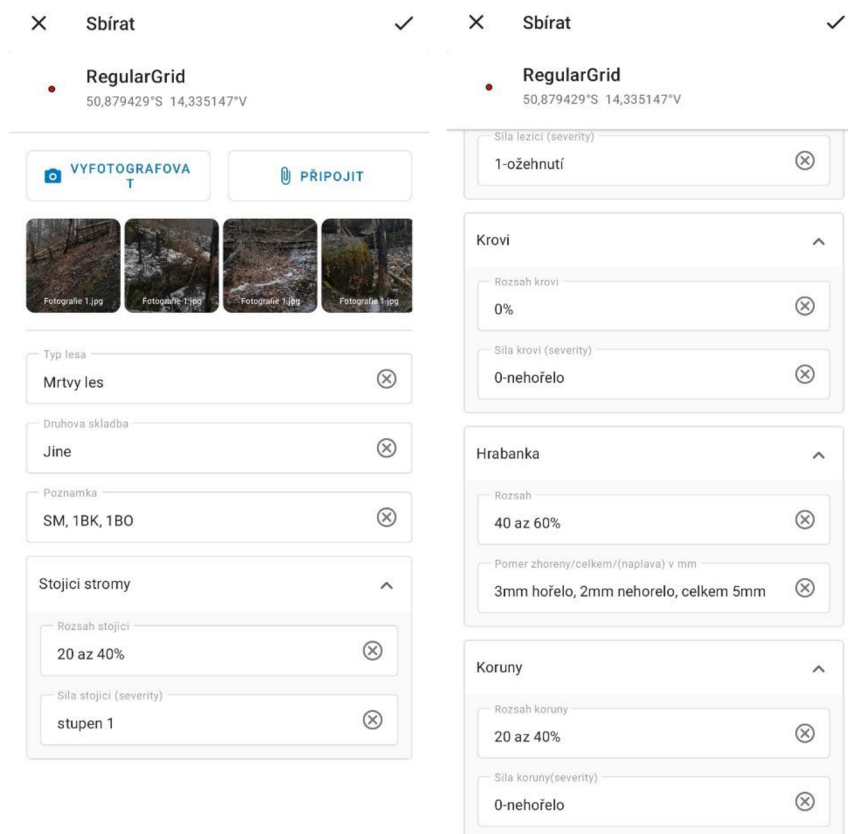
probíhalo měření i v počtu větším než dvě osoby, zvláště ve vyšších polohách a na nebezpečných lokalitách pro pohyb. Přístupnost některých bodů hraničila s nebezpečím úrazu nebo uklouznutím na prudkém svahu, proto byla práce např. v trojici někdy nezbytná. Po celou dobu měření byla dodržována bezpečnostní pravidla, především ohlášení lokalit, kde měření momentálně probíhalo a nošení ochranné helmy na hlavě.

Cílem pozemní inventarizace požářiště bylo odečíst přímo v terénu reálné hodnoty intenzity a severity lesního požáru a použít je jak pro vyhodnocení požáru samotného, tak pro další analýzy a srovnání s jinými metodami hodnocení lesního požáru jako jsou metody dálkového průzkumu země, kterými se zabývá tato práce.

3. 2. 2. Inventarizované veličiny

Zaznamenávána byla (vedle již zmíněného street view, které není předmětem této práce) data, která nám slouží k vyhodnocení intenzity a severity požáru. Konkrétně se jednalo o:

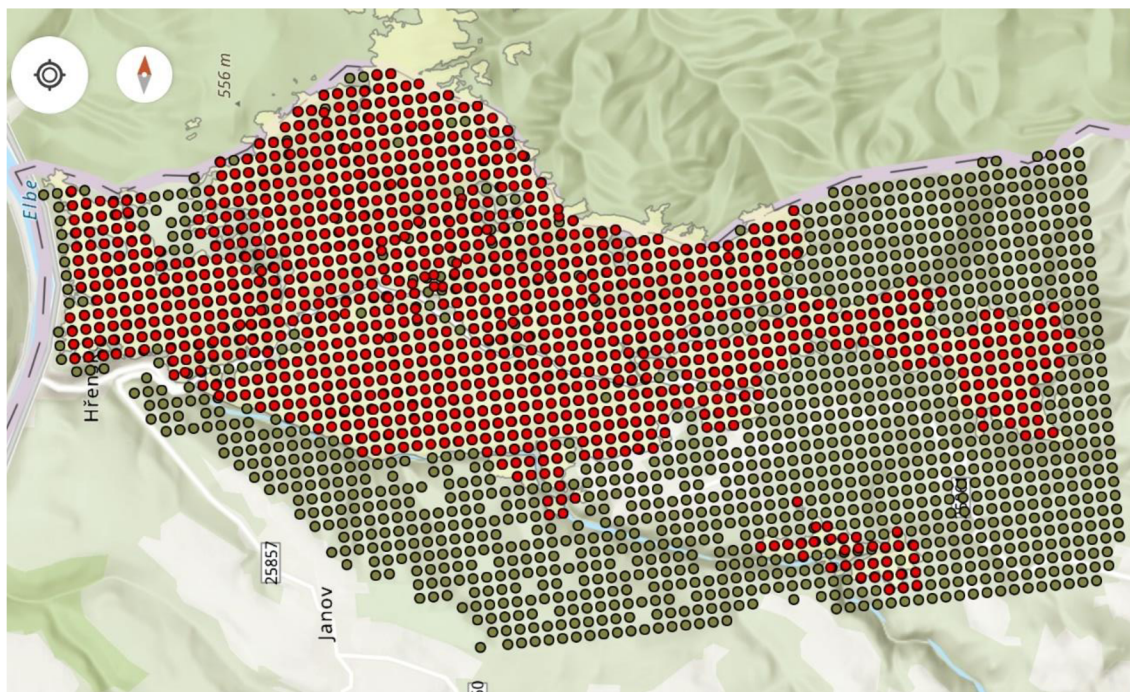
1. Typ lesa: zaznamenávány byly kategorie „Holina“, „Živý les“, „Mrtvý les“, které byly následně kategorizovány číselně jako 0 (holina), 1 (živý les), 2 (mrtvý les)
2. Druhá skladba: zaznamenávány byly kategorie SM (*smrk*), BO (*borovice*), BK (*buk*), BK/BO, Smíšený listnatý, Jiné
3. Poznámka: volitelné pole pro zaznamenávajícího
4. Stojící stromy: hodnocena byla intenzita (rozsah) v kategoriích podle procent 0 %, do 20 %“, 20 – 40 %, 40 – 60 %, 60 – 80 %, více než 80 %.
Dále byla hodnocena severita (síla) v kategoriích „0-nehořelo“, „1-ožehnutí“, „2-mírné ohoření“, „3-střední ohoření“, „4-intenzivní ohoření“.
5. Ležící stromy: byly hodnoceny stejným způsobem jako stojící stromy.
6. Křoví: bylo hodnoceno stejným způsobem jako stojící stromy.
7. Hrabanka: hodnocen byl rozsah prohoření v kategoriích podle procent: 0 %, do 20 %“, 20 – 40 %, 40 – 60 %, 60 – 80 %, více než 80 %.
Dále bylo zaznamenáno, jak hluboko je hrabanka prohořelá z celkové síly hrabanky a případně také jak velká je náplava (vše v mm).
8. Koruny: byly hodnoceny stejným způsobem jako stojící stromy.



Obrázek 5: Výřezy z aplikace Field Maps s poli pro zaznamenání hodnot

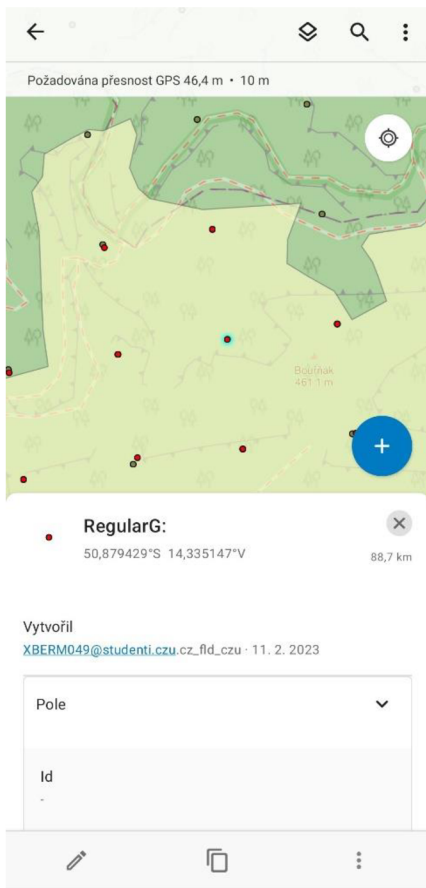
Nástrojem pro zaznamenávání dat byla mobilní aplikace Field Maps od Esri, která je mobilní alternativou k obecně známějšímu Arc GIS pro. Hlavní pomůckou byl tedy pro měření mobilní telefon s přístupem k internetu a k GPS poloze. Další pomůckou byla 3D kamera pro pořízení virtuální prohlídky každé lokality. Tato kamera byla použita ve dvou provedení. Menší byla držena v ruce a větší typ byl na konstrukci určené k nošení na zádech. Kamera byla propojena s mobilním telefonem pomocí Wi-Fi a ovládána aplikací iSTAR Pulsar. Každá plocha má svoje identifikační číslo. Veškerá práce s digitálními přístroji je zaznamenána pomocí bodu v aplikaci Field Maps nicméně pro jistotu byl u virtuální prohlídky 3D kamerou použit také papírový štítek s číslem plochy, protože kamera nezaznamenávala polohu GPS.

Kromě zaznamenání bodů v aplikaci byly body rovněž označovány v terénu. K tomu sloužil ocelový roxor s delší trvanlivostí, aby byl v budoucnu vyhledatelný hledačkou kovů a dřevěný kolík s identifikačním číslem plochy, který však časem zetlí.



Obrázek 6: Výřez z aplikace Field Maps s vyznačenými body ve schematickém uspořádání. Červené body představují inventarizované plochy v územím rozsahu požáru

Pracovní postup zapisování dat do aplikace probíhal následovně: mapa obsahuje vyznačené zájmové území a schematicky umístěné body. Na základě vlastního uvážení (zvolená trasa apod.) byl vybrán bod, který byl v krajině vyhledán pomocí zobrazení vlastní polohy v mapě aplikace. Bod musel být co nejpřesněji zaměřen, proto bylo třeba delší dobu čekat na ustálení kurzoru. V souřadnicích bodu (pokud byl přístupný) byl do země kladivem zasekán roxor a dřevěný kolík, na který bylo napsáno identifikační číslo plochy (to je uvedeno u každého ze schematicky rozmístěných bodů v aplikaci). Dále byl vyměřen poloměr kruhové plochy (12 m) a na okraj této plochy (severním směrem) byl umístěn viditelný předmět (většinou oranžová helma). Na ploše byly zaznamenány výše uvedené veličiny. K tomuto účelu byl do mapy v aplikaci vložen nový bod s červenou barvou pro zapisování dat. Pro změření hrabanky byla vykopána jedna či více malých sond a pomocí metru byly odečteny hodnoty. Plocha byla také zdokumentována pěti fotografiemi na mobilní telefon (kolík, sever, východ, jih, západ), které byly následně nahrány do aplikace Field Maps rovněž do nově založeného bodu. Plochy, které byly také foceny 3D kamerou (virtuální prohlídka), byly označeny v mapě dalším bodem (modrým), který pouze informuje, která plocha byla focena aniž by



modrý bod obsahoval další informace. Při pořizování záběru virtuální prohlídky nesměly být viděny žádné další osoby. Rovněž byl do záběru (severním směrem) umístěn bílý papír s ID plochy pro následné zařazení snímku do systému.

Obrázek 7: Formulář červeného bodu pro zapisování hodnot s náhledem do mapy obsahující záj. území a body



Obrázek 8: Fotodokumentace plochy č. 1513. Foto kolíků (vlevo) a foto směrem do jedné ze světových stran na ploše (vpravo)

Hodnoty stanovené intenzity a severity poškození stojících stromů, ležících stromů, křoví a korun v procentech byly v aplikaci Arc GIS pro (resp. Field Maps) převedeny do kategorií od 0 do 5. Podobně u typu lesa byly tři kategorie (mrtvý les, holina, živý les) převedeny na kategorie 0, 1 a 2. Data z aplikace Arc GIS pro byla exportována do MS Excel. U hodnot pro hrabanku byly výpočty prováděny jak pro míru prohoření, pro hloubku hrabanky samotné, tak pro procentuální podíl prohořelé hrabanky vůči její celkové síle.

Výstupem z pozemní inventarizace požářiště NPCŠ jsou hodnoty odečítané na každé ploše. Ploch bylo celkem 1093 a byly rozmístěny schematicky 100 m od sebe bez ohledu na přístupnost terénu. Výsledná tabulka Excel je výstupem z aplikace Field Maps resp. ArcGIS pro, které sloužily v terénu k zapisování dat. Některá data, která byla přiřazována do kategorií podle procent (např. intenzita nebo severity) byly v tabulce převedeny do kategorií od 0 do 5. Podíl prohořelé hrabanky byl převeden na samostatné hodnoty „hloubka hrabanky“, „síla prohoření hrabanky“, „procentuální míra prohoření hrabanky“. Kromě těchto hodnot obsahuje tabulka kategorizované hodnoty pro severity stojících stromů, severity ležících stromů, severity poškození korun, a totéž pro intenzitu poškození těchto prvků porostu. Zaznamenána byla také druhová skladba a typ lesa. Jako doplněk k inventarizaci byly na plochách pořizovány snímky tzv. virtuální prohlídky (ang. street view). S těmito snímky však tato práce nepočítá.

3. 2. 3. Data LiDAR z letadla

První ze dvou sad dat DPZ jsou data LiDARu, který snímá povrch Země (digitální model povrchu). Jejich obsahem jsou údaje o prostorovém uspořádání zemského povrchu a jeho změnách v čase. Na základě snímkování před a po události lze vypočítat rozdílové hodnoty, tedy takové hodnoty, které poukazují na změnu povrchu (nikoliv terénu), a tedy např. na spadlé stromy. Pokud došlo k pádu většího množství stromů v některé oblasti během krátké doby (ta se dá definovat časovým úsekem kdy byly pořizeny snímky), lze se domnívat, že je to zapříčiněno lesním požárem. Následná analýza dat porovnáním jak s indexem NDVI, tak s daty pozemní inventarizace může prokázat např. shodu naměřené intenzity hoření z dat inventarizace a dat LiDAR. To by poukazovalo na velkou intenzitu požáru, v jehož důsledku stojící stromy (pravděpodobně souše) skácely.

Data jsou tvořena sadou hodnot pro každou z inventarizovaných plošek. Sada obsahuje hodnoty: Count, Area, Min, Max, Range, Mean (průměr), STD (směrodatná odchylka), Sum (součet), Median, PCT90.

3. 2. 4. Spektrální snímky RED, NIR a NDVI z letadla

Spektrální snímky NIR a RED pocházejí rovněž z letadla a byly pořízeny před a po požáru v roce 2022. Pro účely tohoto výzkumu byly hodnoceny plošky o průměrné rozloze 500 m². Z obou sad máme k dispozici hodnoty NIR a RED (kde pro RED byly dvě hodnoty a pro výpočet NDVI byla použita nižší). Tyto hodnoty lze získat opět pomocí GIS, konkrétně nástroje Zonal statistics v aplikaci Arc GIS pro, která vyhodnotí pro každou plošku z pixelů spektrálního snímku příslušné hodnoty pro blízké infračervené záření a červenou oblast záření, které jsou nejcitlivější pro vegetaci. Z obou sad snímků, resp. z jejich již vypočítaných hodnot je zapotřebí získat výsledný NDVI.

Obecně platí, že čím více vitální je porost/flora (tedy zelenější), tím vyšší je hodnota NDVI a odrazivost NIR. Naopak pokud je vegetace odumřelá a pixely snímku obsahují více „šedi“, NDVI se snižuje. Hodnota NDVI koreluje se severitou hoření, protože čím vyšší severita hoření (čím silnější je hoření) tím více šedé (až černé) pixely obsahují. Platí tedy, že klesá-li NDVI, stoupá severita a naopak. Záporné hodnoty v intervalu [0 ; -1] značí severitu. Čím blíže k číslu 1 (nebo -1) tím významnější hodnota je. S kladnými hodnotami se zvyšuje NDVI (platí, že stoupá-li jedna hodnota, stoupá i druhá) a s prohlubujícími se zápornými hodnotami se zvyšuje severita (platí, že stoupá-li jedna hodnota, druhá klesá). V případě záporných hodnot tedy klesá NDVI a stoupá severita, což značí silný požár/žádnou vegetaci.

Index NDVI tedy vypočítáme podle následujícího vzorce:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Výsledná čísla indexu jsou v našem případě záporná. Index NDVI před požárem obsahuje vyšší hodnotu než NDVI po požáru, což odpovídá přítomnosti požáru, kdy se z povrchu vytrácí zelená barva, a tedy živá vegetace a přibývá šedé až černé barvy.

Hodnota představující rozdíl mezi oběma indexy, tedy rozdílový NDVI vypočítáme jako:

$$+ (NDVI \text{ before}) - (NDVI \text{ after})$$

Velikost čísla NDVI rozdílového představuje velikost změny na vegetaci. Zjednodušeně tedy, že čím vyšší hodnota NDVI rozdílového, tím silnější požár na dané ploše pravděpodobně byl. Pro statistické vyhodnocování dat byly stěžejní tyto tři hodnoty NDVI (před a po požáru a rozdílový NDVI).

3. 3. Statistické vyhodnocování dat

Práce s daty byla rozdělena do tří částí. V první části byla posuzována míra závislosti pozemně inventarizovaných veličin navzájem (kapitola 3.3.1.), a to např. pro zjištění vlivu shořelé hrabanky na rozsah poškození stromů apod. Ve druhé části byla zkoumána závislost NDVI na různých měřených veličinách pozemní inventarizace jako např. závislost rozdílového NDVI na severitě poškození stojících stromů apod (kapitola 3.3.2.). Třetí část je věnována regresní analýze nejvýznamnějších korelací mezi NDVI a pozemně inventarizovanými veličinami (kapitola 3.3.3.).

3. 3. 1. Testování vzájemných vztahů veličin pozemní inventarizace

Nejprve byly testovány některé v terénu naměřené hodnoty mezi sebou pro lepší představu o tom, jaké veličiny spolu nejvíce souvisí, a to tak, že byla vždy korelována vždy dvojice veličin, u které se jeví logická souvislost. Pomocí korelační analýzy byly testovány veličiny: intenzity ležících stromů, stojících stromů a křoví a severity ležících stromů, stojících stromů a křoví s veličinami, které by je mohly přímo ovlivňovat, tedy s: intenzitou poškození hrabanky (plošně), mírou prohoření hrabanky, celkovou hloubkou hrabanky, intenzitou poškození korun a severitou poškození korun (viz. tabulka 1). Typ lesa byl porovnáván s: intenzitami poškození stojících a ležících stromů a korun, severitami stojících a ležících stromů a korun. Dále byl srovnáván s intenzitou poškození hrabanky, protože tato hodnota se ukázala v předchozích korelacích jako významná. Pro ilustraci byly severity a intenzity poškození stojících a ležících stromů zobrazeny v krabicovém grafu. Pro analýzu vlivu typu lesa na severitu a

intenzitu poškození, byla použita jednofaktorová ANOVA analýza s Tukeyho post hoc testem.

Kromě ANOVA analýzy a Tukeyho post hoc testu byla ostatní analýza dat v rámci pozemní inventarizace provedena v prostředí MS Excel a pro každou testovanou dvojici dat byla vždy vybrána kompletní sada hodnot příslušné veličiny pro 1093 ploch včetně případů, kdy pro plochu nebyla k dispozici konkrétní hodnota.

Tabulka 1: Výsledky korelační analýzy vzájemně testovaných hodnot pozemní inventarizace

	hrabanka int	hrabanka hoř	hrabanka celk	hrabanka %	koruny int	koruny sev
SEV down tree	0,5534	0,1575	0,1709	-0,0074	0,4185	0,6034
INT down tree	0,6053	0,0336	0,0552	0,0124	0,3429	0,3672
SEV kroví	0,2031	-0,0488	0,0064	-0,0271	0,1850	0,1191
INT kroví	0,2303	-0,0462	0,0221	-0,0495	0,1908	0,0895
SEV stand tree	0,4776	0,0962	0,0621	0,0203	0,5075	0,6034
INT stand tree	0,6146	0,0418	0,0296	0,0446	0,4417	0,3896

Uvedené dvojice veličin testované korelační analýzou se držely následující úvahy: hoří-li hrabanka, jaký vliv bude mít na poškození kmenů stromů ležících, stojících a na křoví? Platí, že je-li (plošná) intenzita prohořelé hrabanky vysoká, je také vysoká severita a intenzita poškozených stromů? Jsou-li poškozeny stromy, koreluje hodnota severity či intenzity se severitou a intenzitou poškození korun těchto stromů (stromů na ploše)?

3. 3. 2. Testování vztahu hodnot NDVI a dat pozemní inventarizace

Dále byly testovány pomocí korelační analýzy hodnoty NDVI rozdílového, NDVI před požárem a NDVI po požáru s většinou veličin naměřených pozemní inventarizací. V této části testování se již posuzuje, do jaké míry jsme schopni rozsah požáru odvodit z dat DPZ.

Korelační analýza tedy byla provedena vždy na dvojici kompletních hodnot pro 1093 ploch, přičemž trojice NDVI byla korelována s intenzitou stojících stromů, severitou stojících stromů, intenzitou ležících stromů, severitou ležících stromů, intenzitou poškození křoví, severitou poškození křoví, intenzitou (co do plochy) poškození hrabanky, hodnotou hloubky prohořelé hrabanky, hodnotou celkové hloubky hrabanky, procentuálním podílem prohořelé hrabanky vůči její celkové hloubce, severitou poškození korun a intenzitou poškození korun stromů. Druhá skladba zaznamenaná pro

každou měřenou plochu (ačkoliv tento údaj není ve skutečnosti zaznamenán pro všechny plochy) byla s NDVI porovnána vizuálně pomocí krabicových grafů (boxplot) pro zjištění závislosti druhu dřeviny na velikosti indexu NDVI.

Protože korelační analýza ukázala, že relevantní pro bližší testování jsou jen výsledky korelační analýzy týkající se severity poškození stromů (stojících i ležících) s NDVI po požáru, byly následně testovány jen tyto dvě hodnoty pomocí regresní analýzy. Přestože rozdílový NDVI by měl ukazovat změnu ve vegetaci po požáru, a tedy závislost velikosti rozdílu NDVI a velikosti požáru, ukázala se jako signifikantní hodnota NDVI po požáru. Hodnota NDVI před požárem je totiž ovlivněna stavem porostů před požárem. To však nemusí být relevantní, protože stav před požárem nemusí být nutně vynikající. Proto je hodnota NDVI před požárem nerelevantní, stejně tak jako následná hodnota rozdílového NDVI, ve srovnání s finální hodnotou NDVI po požáru stanoveného ve stejnou dobu, kdy probíhal sběr pozemních dat. I přesto je u zmíněné severity stromů výsledná hodnota analýzy nízká (mezi 0,3 a 0,4).

V případě NDVI před požárem ukazovaly výsledky korelační analýzy především na vztah severity stojících i ležících stromů (což odpovídá korelaci s NDVI po požáru). Hluboko záporný NDVI před požárem totiž ukazuje na vysokou severitu. Z toho lze vyvodit, že stav lesa před požárem již musel být velice náchylný na hoření a jeho vitalita byla zřejmě velice nízká.

Nezanedbatelné byly ještě výsledky dvojic NDVI po požáru s intenzitou stromů (stojících i ležících), intenzitou poškození hrabanky a severitou poškození korun. U rozdílového NDVI to byly hodnoty korelace s intenzitou poškození stromů a korun a s intenzitou poškození hrabanky. Proto byly dále testovány jen dvě zmíněné hodnoty, které byly vyšší než 0,3 (viz. tabulka 2).

Tabulka 2: Výsledky korelační analýzy hodnot NDVI s referenčními hodnotami inventarizace

	INT stand tree	SV stand tree	INT down tree	SV down tree	SV krovi	INT krovi
NDVI dif	0,2051	0,1751	0,2271	0,1977	0,2044	0,2223
NDVI before	-0,1088	-0,3552	-0,1874	-0,2850	-0,0154	0,0373
NDVI after	-0,2266	-0,3959	-0,3026	-0,3574	-0,1540	-0,1258

	hrabanka INT	hrabanka shor	hranka celk	hrabanka %	INT krouny	SV koruny
NDVI dif	0,2352	-0,0565	-0,0378	0,0663	0,2142	0,1928
NDVI before	-0,1566	-0,0576	-0,0292	-0,0239	-0,1528	-0,2152
NDVI after	-0,2844	-0,0064	0,0031	-0,0649	-0,2669	-0,3002

3. 3. 3. Testování vztahu hodnot LiDAR s NDVI a daty pozemní inventarizace

Data LiDAR byla testována rovněž nejprve pomocí korelační analýzy pro zjištění nejlepších vztahů mezi veličinami, a to jak s referenčními daty získanými pozemní inventarizací, tak s NDVI po požáru. Stejně jako v případě testování NDVI s referenčními hodnotami korelační analýzou, byla zde použita data pro všech 1093 ploch. Výsledky nejlepších korelací jsou v tabulce 3 a 4.

Tabulka 3: Výsledky korelace mezi LiDAR (aktivní senzory) a NDVI (pasivní senzory)

NDVI after, MEAN 0,48053	NDVI after, STD -0,4335	NDVI before, MEAN 0,4957
------------------------------------	-----------------------------------	------------------------------------

Tabulka 4: Výsledky korelace mezi LiDAR (aktivní senzory) a vybranými veličinami pozemní inventarizace, které se ukázaly být nejvíce související

SVStanTree a MEAN -0,55638	SVDowTree, MEAN -0,43644	SVKoruny, MEAN -0,32089
IntStanTree a MEAN -0,33723	IntKoruny, MEAN -0,29563	

Na významné souvislosti ukazují především korelace NDVI po požáru s LiDAR (větší 0,4), rovněž NDVI before s LiDAR MEAN (průměr) a LiDAR MEAN se severitou stojících stromů, kde byla hodnota větší 0,5. Nezanedbatelné korelace vycházely také u severity poškození korun, intenzity poškození stojících stromů a intenzity poškození korun s LiDAR MEAN (průměr).

Pro korelace s LiDAR byla použita nejčastěji hodnota MEAN – průměr, která představuje velikost rozdílu ve výškách (např. stojících stromů) na jedné testované ploše, tj. cca. 500 m². V některých případech vycházely zajímavé korelace také s hodnotou STD – směrodatná odchylka, která představuje změnu v pestrosti výšek na hodnocené ploše před a po události (v tomto případě požáru).

3. 3. 4. Lineární regrese a Stepwise regrese


Pro vyhledání nejlepších prediktorů z datové sady DPZ byla zvolena lineární regresní analýza a následná Stepwise regresní analýza. Zatímco lineární regrese je základním nástrojem pro určování povahy vztahu mezi indikátorem a prediktory (nebo

obecně proměnnými), Stepwise regrese funguje na principu postupného přidávání nebo ubírání prediktorů na základě jejich statistické významnosti, a tím se snaží nalézt optimální sadu prediktorů pro vysvětlení variací závislé proměnné – indikátoru. Analýzy proběhly v prostředí softwaru R Studio (program pro statistické vyhodnocování dat).

3. 3. 5. Použití modelů strojového učení RF a SVM

Protože pro datovou sadu se ukázala být regresní analýza neefektivní, byly zvoleny pokročilejší metody ke tvorbě modelů. Prvním modelem strojového učení je *Random Forest* (RF), který funguje na principu vytváření rozhodovacích stromů během tzv. trénování dat. To probíhá na náhodně vybrané podmnožině dat, což je také příčinou, že výsledky modelu se od sebe mohou mírně lišit při vícečetném spuštění pro stejný indikátor. Jedná se o tzv. esemblovou metodu kombinovaných modelů supervizovaného učení. Při tvorbě modelu dochází k redukci variance vzájemně testovaných hodnot bez výrazného zkreslení.

I přes mírné zlepšení modelu, které přinesl RF, byla hledána alternativní metoda. Proto byl jako druhý model zvolen *Support Vector Machine* (SVM), který na rozdíl od RF, který vytváří soubor pravidel na náhodně vybraných podmnožinách dat, tento nachází optimální hranici mezi třídami – tzv. hyperrovinu (nebo i více hyperrovin ve vyšších dimenzích), která je schopna nejlépe oddělit třídy v prostoru proměnných. Základním principem této metody je maximalizace marginu (vzdálenosti mezi hyperrovinou a nejbližšími datovými body z každé třídy, které jsou označovány jako podpůrné vektory). Základním balíčkem, který je použitý v R pro práci se SVM je *Caret* (Kuhn, 2019)



Obrázek 9: Pomocné grafické zobrazení rozdělení dat podle SVM (Manjrekar et al., 2019)

4 VÝSLEDKY

4.1. Výsledky analýzy vzájemných vztahů veličin inventarizace

Korelační analýza vzájemných vztahů mezi naměřenými daty v požářišti NPCŠ ukázaly, které veličiny spolu nejvíce souvisely v procesu hoření porostu. Jedná se o analýzu, jejíž snahou je více porozumět samotnému požáru v porostu z pohledu dat nasbíraných při pozemní inventarizaci. Nejedná se tedy o analýzu dat DPZ.

4.1.1 Korelační analýza dat pozemní inventarizace

Tabulka 5: Výsledky korelační analýzy severity a intenzity poškození křoví s hodnotami hrabanky a korun stromů

	hrabanka int	hrabanka hoř	hrabanka celk	hrabanka %	koruny int	koruny sev
SEV křoví	0,20309	-0,04878	0,00644	-0,02707	0,18502	0,11910
INT křoví	0,23034	-0,04618	0,02207	-0,04955	0,19082	0,08952

Výsledky korelační analýzy severity a intenzity poškození křoví s hodnotami poškození hrabanky a stromových korun se ukázaly jako nejmenší oproti dalším výsledkům korelací. Na velice nízkou severitu ukazují také korelace severity a intenzity poškození křoví se silou prohořelé hrabanky a procentuálním zastoupením prohořelé hrabanky z její celkové hloubky (SEV křoví a hrabanka hoř, hrabanka % a INT křoví a hrabanka hoř, hrabanka %). Závislost poškození křoví je malá v korelacích s intenzitou shořelé hrabanky a s poškozením korun stromů. Nejmenší závislost se ukázala při korelaci s hodnotou tloušťky hrabanky, což ukazuje na to, že její hloubka nehrála při požáru takovou roli.

Tabulka 6: Korelace hodnot hrabanky a stromových korun se severitou poškození ležících stromů

	hrabanka int	hrabanka hoř	hrabanka celk	hrabanka %	koruny int	koruny sev
SEV down tree	0,55344	0,15749	0,17093	-0,00739	0,41846	0,60342

Testování severity poškození ležících stromů ukázalo největší korelace se severitou poškození stromových korun (0,603), intenzitou poškození hrabanky (0,553) a intenzitou poškození stromových korun (0,418). Tyto výsledky potvrzují celkem logický vztah mezi poškozením koruny a celého stromu ale i požáru hrabanky a ležícího stromu. Korelace se silou prohořelé hrabanky, celkovou hloubkou hrabanky a procentuálním podílem prohořelé hrabanky vůči její celkové hloubce se ukázaly jako zanedbatelné.

Tabulka 7: Korelace hodnot hrabanky a stromových korun s intenzitou poškození ležících stromů

	hrabanka int	hrabanka hoř	hrabanka celk	hrabanka %	koruny int	koruny sev
INT down tree	0,60534	0,03360	0,05515	0,01239	0,34295	0,36719

Testování intenzity poškození ležících stromů ukázalo největší korelace s intenzitou poškození hrabanky (0,605). Tyto dvě veličiny spolu opět úzce souvisejí, protože ležící stromy se přímo dotýkají hrabanky. Další nezanedbatelné hodnoty představují korelace s intenzitou a severitou poškození stromových korun (0,342 a 0,367). Ostatní hodnoty (viz. tabulka 7) jsou zanedbatelné.

Tabulka 8: Korelace hodnot hrabanky a stromových korun se severitou poškození stojících stromů

	hrabanka int	hrabanka hoř	hrabanka celk	hrabanka %	koruny int	koruny sev
SEV stand tree	0,47761	0,09616	0,06213	0,02031	0,50747	0,60342

Testování severity poškození stojících stromů ukázalo největší korelace se severitou poškození stromových korun (0,603), s intenzitou poškození stromových korun (0,507) a s intenzitou poškození hrabanky (0,477). Hodnoty potvrzují úzkou souvislost mezi kmenem stromu a korunou, a hrabankou s kmenem stromu. Všechny ostatní veličiny se v korelacích ukázaly být zanedbatelné (viz. tabulka 8).

Tabulka 9: Korelace hodnot hrabanky a stromových korun s intenzitou poškození stojících stromů

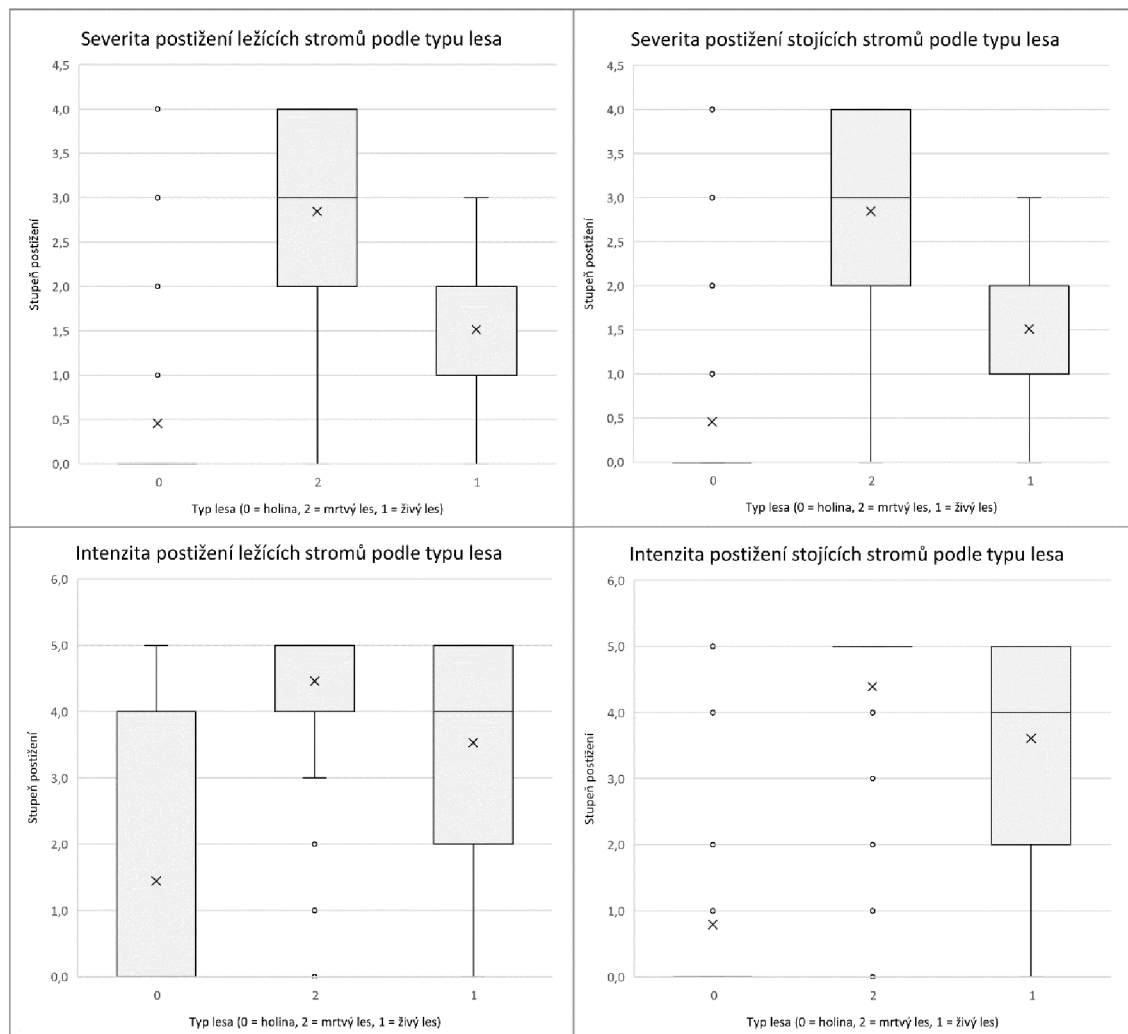
	hrabanka int	hrabanka hoř	hrabanka celk	hrabanka %	koruny int	koruny sev
INT stand tree	0,61460	0,04181	0,02962	0,04459	0,44172	0,38960

Testování intenzity poškození stojících stromů ukázalo největší korelace s intenzitou poškození hrabanky (0,614) a s intenzitou poškození stromových korun (0,441). Tyto výsledky opět dokládají vzájemný vztah hrabanky a stojícího kmene, a kmene s korunou při procesu hoření. Přestože ohoření kmene úzce souvisí s hořením koruny, ne vždy byla intenzita požáru taková, aby dosáhla až do korunové úrovně.

V rámci zkoumání vzájemných vlivů při požáru porostu na základě dat inventarizace bylo také zapotřebí prozkoumat do jaké míry souvisí typ lesa se severitou a intenzitou požáru. Jak bylo již zmíněno v úvodu (kapitola 1), nejnovější výzkum Bobka et al. (2023) poukázal na výrazný vliv typu lesa na rychlost šíření požáru porostem, a také na přítomnost podzemního požáru. V následujícím, grafu je zobrazen stupeň postižení porostu v každém ze tří typů lesa (mrtvý, živý a holina).

4. 1. 2. Stupně zasažení požárem podle typu lesa

Graf 1: Postižení požárem podle typu lesa



Síla (severita) postižení ležících stromů požárem je největší v mrtvém lese, kde dosahuje stupně 2 až 4. To odpovídá skutečnosti, že mrtvé ležící stromy jsou v přímém kontaktu s hrabankou, kde se síla požáru může nejvíce projevit jak přímým kontaktem hořící hrabanky a kmene, tak lepší hořlavostí suchého mrtvého dřeva.

Síla postižení stojících stromů je rovněž nejvyšší v mrtvém lese, kde dosahuje stupně postižení 2 až 4. Výsledky jsou tedy téměř shodné s výsledky pro severitu postižení ležících stromů. Zde rovněž platí, že suché stojící stromy vystavené slunečnímu záření a proudění větru jsou náchylnější k hoření.

Intenzita (plošné postižení) ležících stromů byla v největším rozsahu na holinách (0 až 4), v živém lese (2 až 5) a nejintenzivnější požár byl v mrtvém lese, kde většina

hodnot je mezi stupni 4 a 5. Hodnoty odpovídají skutečnosti, že ležící stromy na holině jsou v přímém kontaktu s hrabankou a jsou tedy nejvíce plošně zasaženy hořením. V živém lese, kde se mj. nacházel místy také podzemní požár (Bobek et al., 2023), dosahovala plošná intenzita ohoření dokonce stupně 5. Nejvíce intenzivní postižení ležících stromů bylo v mrtvém lese, což koreluje s předchozími tvrzeními, kdy prosvětlený mrtvý les, ve kterém snáze dřevu prosychá v důsledku otevřeného proudění vzduchu je nejnáchylnější na hoření (je nejlepším palivem).

Intenzita postižení stojících stromů byla nejvyšší mrtvém lese (stupeň 5) a v živém lese, kde se hodnoty pohybovaly od stupně 2 po stupeň 5.

Pro ověření, zda má typ lesa statisticky významný vliv na měřenou proměnnou (severitu a intenzitu stojících a ležících stromů), byla použita jednofaktorová ANOVA analýza s post hoc Tuckeyho testem v prostředí softwaru R a R Studio.

Vliv typu lesa na severitu postižení ležících stromů:

Df	Sum Sq	Mean Sq	F value	Pr(>F)
Typ_lesa	2	757	378.5	294 <2e-16 ***
Residuals	1089	1402	1.3	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				

P hodnota se blíží nule, což ukazuje na velmi významný rozdíl mezi typy lesa a jejich vliv na severitu postižení ležících stromů. Rovněž vysoká F hodnota ukazuje, že průměry mezi skupinami se od sebe významně liší.

Tukey multiple comparisons of means				
95% family-wise confidence level				
Fit: aov(formula = TreeDWNsev ~ Typ_lesa, data = F)				
\$Typ_lesa	diff	lwr	upr	p adj
1-0	1.154990	0.9341316	1.375849	0
2-0	2.251945	2.0293389	2.474552	0
2-1	1.096955	0.9170562	1.276853	0

Tukeyho post hoc test specifikoval, že mezi všemi třemi skupinami je rozdíl ve středních hodnotách vždy s 95 % konfidenčním intervalem a s p-hodnotou menší než 0,05. Z uvedených výsledků tedy jasně vyplývá nezávislost mezi typem lesa a severitou postižení ležících stromů.

Identicky zle popsat výsledky těchto testů pro zbývající tři testované skupiny (Graf 1):

Vliv typu lesa na severitu postižení stojících stromů:

```
Df Sum Sq Mean Sq F value Pr(>F)
Typ_lesa      2      893    446.5   483.6 <2e-16 ***
Residuals    1089     1005      0.9
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

    Tukey multiple comparisons of means
    95% family-wise confidence level

Fit: aov(formula = StanTreesV ~ Typ_lesa, data = F)

$Typ_lesa
      diff      lwr      upr      p adj
1-0      1.056435 0.8694187 1.243452      0
2-0      2.389980 2.2014839 2.578477      0
2-1      1.333545 1.1812120 1.485878      0
```

Vliv typu lesa na intenzitu postižení ležících stromů:

```
Df Sum Sq Mean Sq F value Pr(>F)
Typ_lesa      2     1304    651.8   236 <2e-16 ***
Residuals    1089     3007      2.8
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

    Tukey multiple comparisons of means
    95% family-wise confidence level

Fit: aov(formula = TreeDWNint ~ Typ_lesa, data = F)

$Typ_lesa
      diff      lwr      upr      p adj
1-0      2.0882064 1.7647618 2.411651      0
2-0      3.0160835 2.6900797 3.342087      0
2-1      0.9278771 0.6644182 1.191336      0
```

Vliv typu lesa na intenzitu postižení stojících stromů:

```
Df Sum Sq Mean Sq F value Pr(>F)
Typ_lesa      2     1896    948.0   412.3 <2e-16 ***
Residuals    1089     2504      2.3
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

    Tukey multiple comparisons of means
    95% family-wise confidence level

Fit: aov(formula = streeInten ~ Typ_lesa, data = F)

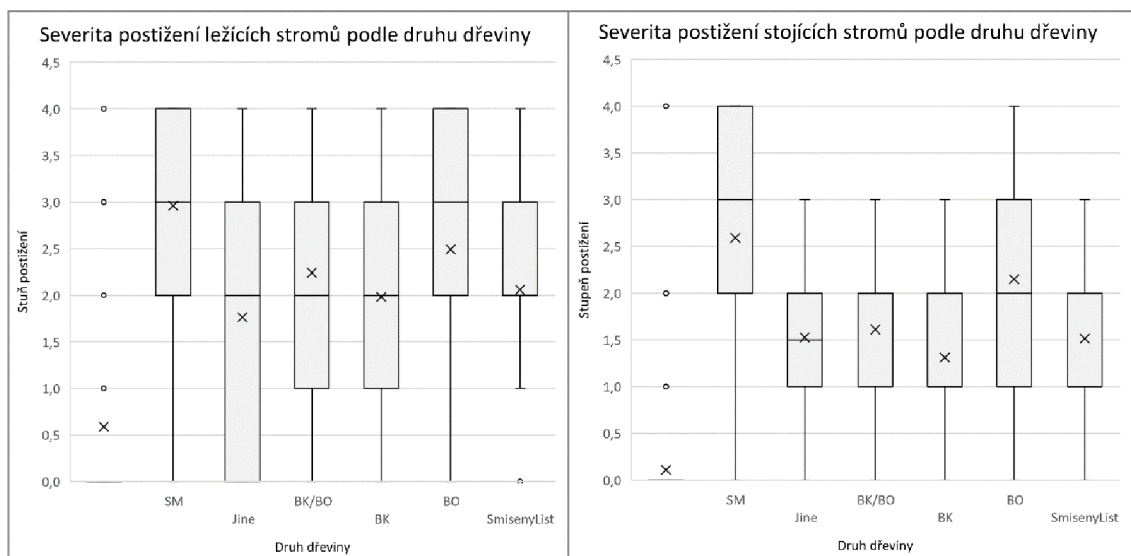
$Typ_lesa
      diff      lwr      upr      p adj
1-0      2.8126690 2.5175284 3.107810      0
2-0      3.5948381 3.2973623 3.892314      0
2-1      0.7821691 0.5417649 1.022573      0
```

Ze všech čtyřech výsledků testování jednofaktorovou ANOVA analýzou vyplývá, že typ lesa má zásadní (a tedy nenáhodný) vliv na intenzitu i severitu poškození porostu, což odpovídá zobrazení v Grafu 1. Ve všech případech je rozdíl ve středních hodnotách větší než 95 % a p-hodnota menší než 0,05.

4. 1. 3. Stupně zasažení požárem podle druhu dřeviny

Dalším zkoumaným vztahem je druh dřeviny a míra jejího poškození. Zde nás zajímá, která dřevina se ukázala být jako nejvíce hořlavá ze všech zaznamenaných dřevin v rámci inventarizace, přičemž druhy dřeviny byly porovnávány s intenzitou a severitou poškození stojících i ležících stromů, protože tyto veličiny mají předpoklad být nejvíce související s druhem dřeviny (vedle stromových korun).

Graf 2: Severita poškození ležících a stojících stromů podle druhu dřeviny




Jak ukazuje graf vlevo, největší severita (síla) požáru postihla ležící smrky a borovice, kde se hodnoty severity pohybují většinou od stupně 2 do stupně 4, přičemž střední hodnota je na stupni 3. To potvrzuje, že nejvíce hořlavé jsou jehličnaté dřeviny.

Graf vpravo (graf 2), který zobrazuje distribuci hodnot severity poškození stromů stojících, ještě výrazněji poukazuje na hořlavost smrku. Do jisté míry to je dáno také tím, že na území NP jsou rozsáhlé plochy mrtvého stojícího smrku po kůrovcové kalamitě. To vysvětluje, proč zde, na rozdíl od stromů ležících, jsou hodnoty pro smrk

vyšší než pro borovici, přestože i borovice vykazuje vyšší průměrné hodnoty, než jsou hodnoty buku, smíšeného listnatého lesa, směsi buku a borovice a nezařazených porostů. U smrku je střední hodnota postižení na stupni 3, u borovice je na stupni 2.

Graf 3: Intenzita postižení ležících a stojících stromů podle druhu dřeviny



Jak zobrazuje graf 3 (vlevo), dosahují všechny druhy dřevin nejvyššího stupně intenzity postižení ležících stromů, avšak opět u smrku je většina hodnot koncentrována mezi stupni postižení 4 a 5. To poukazuje na vysokou hořlavost smrku, což je v souladu s předchozími výsledky. Druhou dřevinou v pořadí nejvíce zasaženou intenzitou požáru je borovice, která má medián hodnot výše než smíšený listnatý les, který má jinak data mezi třetím a prvním kvantilem distribuována stejně jako u borovice. Anomálii vykazují data jiných dřevin, kde se hodnoty pohybují na celé škále stupňů postižení (0-5), což je dáno rozdílností druhů ve směsi dřevin.

Graf 3 (vpravo) je velmi podobný předchozímu grafu. Zde však u směsi dalších dřevin („Jine“) nejsou hodnoty postižení na celé škále stupňů, což je dáno zřejmě nižší náchylností k ohoření stojících stromů oproti ležícím, které jsou v přímém kontaktu s hrabankou. Hodnoty smrku jsou opět koncentrovány na stupni 4 a 5. Borovice se zde již zřetelněji odlišuje svými hodnotami zasažení od smíšeného listnatého porostu. Hodnoty stojících borovic jsou zde na stupních 3 až 5 s průměrem mírně nad 4.

4. 2. Výsledky analýzy NDVI s daty pozemní inventarizace

Výsledky této analýzy představují velikost shody měření pasivními senzory DPZ s referenčními daty inventarizace. Jedná se o data získaná ze spektrálních snímků, kdy dříve uvedeným výpočtem hodnot červeného světla a blízkého infračerveného záření získáme NDVI (normalizovaný rozdílový vegetační index), z něhož můžeme určovat vitalitu vegetace i rozdíly.

4. 2. 1. Korelační analýza NDVI s referenčními daty inventarizace

V následující tabulce jsou zobrazeny výsledky korelační analýzy. V názvech sloupců jsou testované veličiny inventarizace s NDVI, jejichž typy jsou v názvech řádků. Základním NDVI je „after“, který udává velikost NDVI po požáru, a tedy je pořízen v době, kdy byla sbírána data v terénu. „NDVI before“ obsahuje hodnoty NDVI před požárem a „NDVI dif“ hodnoty rozdílu. Toto číslo tedy představuje velikost změny, která se ve stavu vegetace odehrála v intervalu před vznikem požáru a po něm. Čím zápornější hodnota NDVI je, tím větší severitu ukazuje. Z hodnot NDVI before je zřejmé, že stav (vitalita) vegetace byla již před požárem velmi nízká, což je dáno rozsáhlými kůrovcovými soušemi a holinami. Záporné hodnoty NDVI před požárem totiž ukazují spíše na severitu, než na vitalitu (zelenost) porostu.

Tabulka 10: Výsledky korelační analýzy třech typů NDVI s veličinami pozemní inventarizace

	INT stand tree	SV stand tree	INT down tree	SV down tree	SV krovi	INT krovi
NDVI after	-0,2266	-0,3959	-0,3026	-0,3574	-0,1540	-0,1258
NDVI before	-0,1088	-0,3552	-0,1874	-0,2850	-0,0154	0,0373
NDVI dif	0,2051	0,1751	0,2271	0,1977	0,2044	0,2223

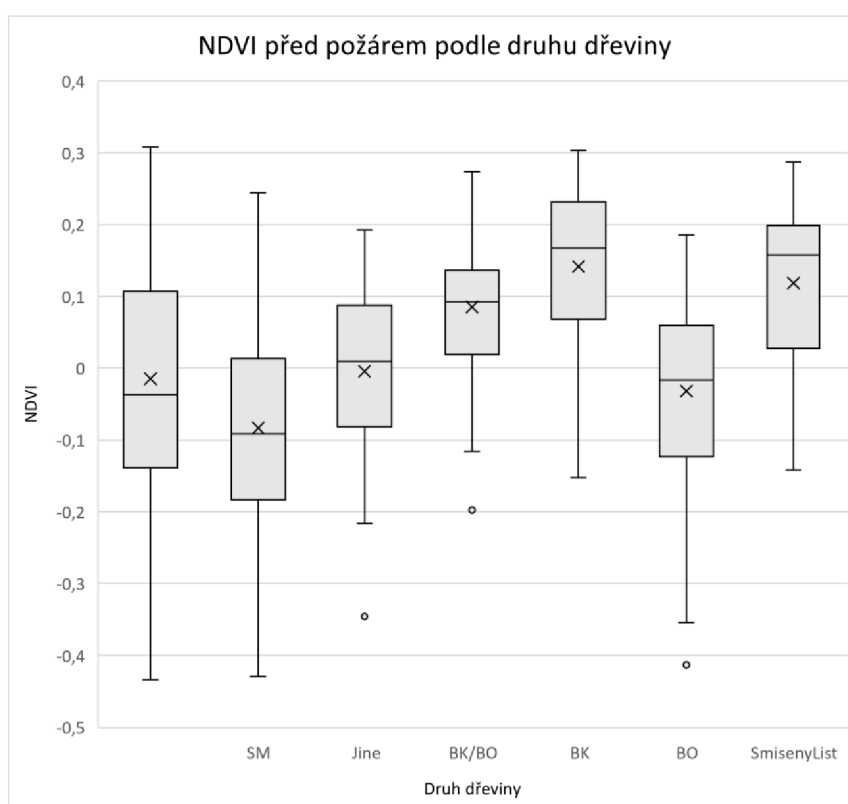
	hrabanka INT	hrabanka shor	hranka celk	hrabanka %	INT krouny	SV koruny
NDVI after	-0,2844	-0,0064	0,0031	-0,0649	-0,2669	-0,3002
NDVI before	-0,1566	-0,0576	-0,0292	-0,0239	-0,1528	-0,2152
NDVI dif	0,2352	-0,0565	-0,0378	0,0663	0,2142	0,1928

Z hodnot NDVI po požáru, které jsou nejvíce relevantní, je zřejmé, že nejvyšší korelace je se severitou postižení stojících stromů a severitou ležících stromů. Také hodnoty pro intenzitu postižení ležících a stojících stromů jsou nezanedbatelné ($>0,2$). Dále jsou významné korelace s intenzitou postižení hrabanky (-0,284) a s intenzitou a severitou postižení stromových korun (-0,266 a -0,3).

Protože hodnoty korelační analýzy pro NDVI after nejsou příliš vysoké (ale ani zanedbatelné), a protože hodnoty NDVI before jsou jasně záporné (oproti očekávaným kladným hodnotám zdravého porostu), ukazují se referenční data (alespoň částečné) inventarizace jako nezbytná pro správné vyhodnocení intenzity lesního požáru. To proto, že stav lesního porostu před požárem může být různý a jeho stav může mít odlišný vliv na následný průběh a šíření lesního požáru.

4. 2. 2. Hodnoty NDVI podle druhu dřeviny


Graf 4: Distribuce hodnot NDVI před požárem podle druhu dřeviny



Z grafu 4 vyplývá, že před požárem byly v nejhorším stavu smrkové porosty, kde většina hodnot je záporných. Průměr i střední hodnota dat pro borovici je rovněž záporná, přestože část hodnot NDVI je kladná. Jako nejvíce vitální se ukazují být bukové porosty se střední hodnotou blížíící se 0,2, a také hodnoty smíšeného listnatého lesa. Distribuce dat s průměrem a střední hodnotou okolo 0 jsou u ostatních dřevin a u ploch s nezařazenou druhovou skladbou (nepopsaný box zcela vlevo). To je dáno proměnlivostí dřevin v této nepopsané skupině, kde některé jsou na požár náchylné, jiné méně.

Dále bylo zkoumáno, jaké hodnoty NDVI mají dřeviny po požáru, což zobrazuje následující graf 5.

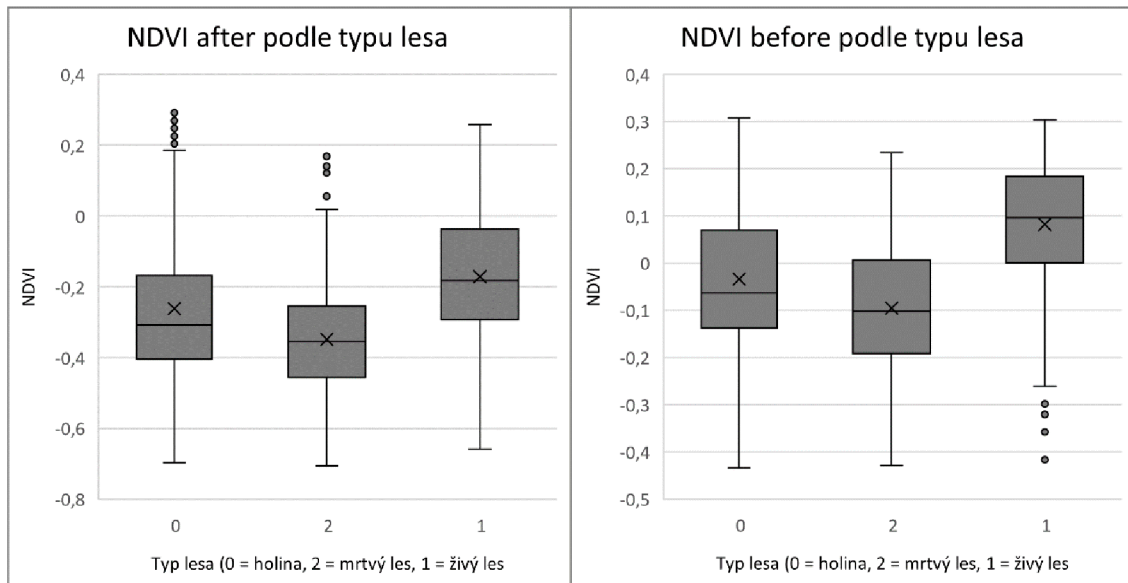
Graf 5: Distribuce hodnot NDVI po požáru podle druhu dřeviny



Při srovnání grafu 4 s grafem 5 je vidět, že tvar distribuce dat podle jednotlivých dřevin je podobný. Jejich hodnoty však výrazně klesly, takže většina hodnot NDVI po požáru je nyní záporná. Střední hodnota i průměr pro smrk je nižší než -0,3. Nejužší distribuce hodnot je u borovice, kde se hodnoty nacházejí mezi -0,2 a -0,4 s průměrem lehce nad 0,3. Pouze u buku přesahuje část hodnot do kladných čísel, avšak s průměrem a střední hodnotou mírně nad -0,1. Z obou grafů je tedy patrné, že požár zasáhl druhovou skladbu relativně rovnoměrně, ale postižení dřevin požárem záviselo na jejich vitalitě, což odpovídá zobrazení v grafu. Distribuce dat představujících diferenční NDVI je tedy pro každou dřevinu podobná (je relativně na stejné hladině), pouze se liší její rozsah. Střední hodnoty i průměry rozdílového NDVI se ve všech kategoriích držely v intervalu [0,2–0,3] s výjimkou směsi buku a borovice, kde je střední hodnota velmi těsně nad 0,3 avšak průměrná hodnota je nižší.

4. 2. 3. Hodnoty NDVI podle typu lesa

Graf 6: Hodnoty NDVI po požáru a NDVI před požárem podle typu lesa



Distribuce hodnot NDVI po požáru a před požárem je velmi podobná distribuci hodnot u typů dřevin v předchozích výsledcích. Rozdílový NDVI ukazuje spíše na rovnoměrné zasažení požárem všech typů lesa. Z hodnot NDVI po požáru vyplývá největší severita postižení u mrtvého lesa, jehož střední hodnota je -0,354 a průměrná hodnota -0,348. U holiny, kde většinou hořely pařezy nebo ležící stromy, byla střední hodnota -0,306 a průměrná hodnota -0,261. V živém lese činila střední hodnota -0,181 a průměrná hodnota -0,171.

Tvar grafu zobrazující distribuci hodnot NDVI před požárem je podobný grafu týkající se stavu po požáru. Hodnoty NDVI však nejsou tak významné, ačkoliv jsou převážně v záporných hodnotách. Střední hodnota NDVI na holině činí -0,062 a průměrná hodnota -0,033. Stejně jako v předchozím grafu, ukazují hodnoty pro mrtvý les před požárem největší severitu. Střední hodnota je zde -0,102 a průměrná hodnota -0,095. V živém lese je střední i průměrná hodnota kladná. Střední hodnota činí 0,096 a průměrná hodnota 0,081.

4. 3. Výsledky analýzy LiDAR s daty inventarizace a srovnání s NDVI

Výsledky analýzy LiDAR (Ligt Detection and Ranging) představují alternativu pro hodnocení stavu vegetace pomocí DPZ. Pro tuto analýzu byly k dispozici hodnoty rozdílového LiDAR, tedy rozdílu bodového mračna před požárem a po něm. Stěžejními veličinami je zde průměrná hodnota, která představuje rozdíl výšek (stromových korun) na každé hodnocené ploše a směrodatná odchylka vyjadřující velikost změny výškových poměrů na ploše.

4. 3. 1. Korelační analýza LiDAR s referenčními daty inventarizace

Pro zjištění změny ve výškové struktuře porostu byly použity hodnoty severity a intenzity poškození stojících stromů, které byly korelační analýzou srovnávány s průměrnou hodnotou LiDAR a se směrodatnou odchylkou.

Tabulka 11: Výsledky korelační analýzy pro stojící stromy

SVStanTree a MEAN	SVStanTree a STD	IntStanTree a MEAN	IntStanTree a STD
-0,55638	0,499895	-0,33723	0,340747

Z uvedených výsledků korelační analýzy vyplývá, že největší vztah je mezi severitou stojících stromů a průměrnou hodnotou LiDAR a směrodatnou odchylkou. To znamená, že severita souvisí s výškovou členitostí porostu a se změnou výškových poměrů, což ukazuje nejspíše na pády stromů v lokalitách s nejvyšší severitou v důsledku požáru. Vysoká hodnota pro směrodatnou odchylku znamená více výškových změn v porostu, které se odehrály v rozmezí před a po požáru. Korelace pro intenzitu stojících stromů s průměrnou hodnotou a směrodatnou odchylkou jsou menší. Intenzita však nemá takový vliv na stabilitu porostu jako severita – síla.

4. 3. 2. Korelační analýza LiDAR s NDVI

Pro zjištění velikosti shody dat DPZ byla provedena i korelační analýza mezi oběma typy dat.

Tabulka 12: Výsledky korelační analýzy mezi dvěma druhy dat DPZ


NDVI after, MEAN	NDVI after, STD	NDVI before, MEAN	NDVI before, STD
0,48053	-0,4335	0,495712	-0,48353

Hodnoty korelací $>0,4$ nebo $>-0,4$ ukazují na vztah hodnoty NDVI po požáru se střední hodnotou i směrodatnou odchylkou. Co je na výsledcích zajímavého, že hodnoty korelací jsou u NDVI před požárem vyšší než po požáru.

4. 3. 3. Analýza vztahu severity stojících stromů s daty LiDAR

Byly použity hodnoty severity stojících stromů pro zobrazení jejich distribuce ve vztahu ke střední hodnotě a směrodatné odchylce bodového mračna hodnocených ploch.


Graf 7: Trend v distribuci průměrných hodnot LIDAR na stupních postižení stojících stromů



Z grafu 7 je patrné, že se zvyšující se severitou stojících stromů na stupnici 0 až 5 je zvětšuje průměrná hodnota. Čím větší je tedy severita, tím více výškových změn v porostu se v důsledku požáru událo. Výsledky tedy dokládají, že na lokalitách s nejvyšší naměřenou silou hoření došlo k pádu stojících stromů a poklesu měřených výškových bodů.

Stejným způsobem byla testována data směrodatné odchylky na všech plochách se severitou stojících stromů pro zjištění míry nerovnoměrnosti poklesu výšek (výškových poměrů).

Graf 8: Trend v distribuci směrodatné odchylky LiDAR na plochách na stupních postižení stojících stromů




Z grafu 8 je patrné, že zde platí stejný trend jako v přechodím případě. Se zvyšujícím se stupněm severity postižení stojících stromů se zvyšuje velikost směrodatné odchylky (v tomto případě v kladných hodnotách). Čím větší byla na plochách naměřena severita, tím větší rozdíly ve výškových poměrech na ploše byly, což opět poukazuje např. na pády stromů v důsledku požáru.

4. 3. 4. Analýza vztahu druhu dřeviny s daty LiDAR


V grafu 7 a 8 byly zobrazeny rozsahy dat pro průměrnou odchylku LiDAR mračna a jeho směrodatnou odchylku pro zjištění, které plochy podle druhové skladby byly nejvíce postihovány výškovými rozdíly a změnami v poměru výšek.

Graf 9: Rozsah průměrných hodnot LIDAR podle druhu dřeviny



Z průměrných hodnot rozdílové LiDAR sady dat je patrné, že největší změny ve výškovém uspořádání byly u smrkových porostů, kde rozsah mezi třetím a prvním kvartilem je od -0,893 do -10,5 a střední hodnota je -4,48. To dokládá zásadní vliv smrku na výškové změny v důsledku požáru a rovněž do odpovídá všem předchozím výsledkům analýz. Naopak hodnoty buku jsou zde nejlepší: mají nejužší rozsah a střední hodnota činí 0,198. To značí odolnost a vitalitu bukových porostů a minimální podíl na prostorových změnách v porostu.

Graf 10: Rozsah směrodatných odchylek hodnot LiDAR podle druhu dřeviny



Rozsahy dat směrodatné odchylky LiDAR jsou již u všech klasifikovaných dřevin větší. Nejvyšší hodnotu směrodatné odchylky má opět smrk se střední hodnotou 8,673. Střední hodnota buku je 3,72 a borovice 5,13. Větší intervaly druhého a třetího kvartilu ukazují na větší variabilitu hodnot v rámci dřeviny. Z výsledků vyplývá, že ve smrkových porostech došlo k největším výkyvům ve výškových poměrech porostů na měřených plochách, a tedy k nejvyšší severitě (síle) postižení v jejímž důsledku stromy v porostu padaly.

4. 4. Výsledky vícefaktorové analýzy

4. 4. 1. Vícefaktorová lineární regrese a stepwise regrese

Pro modelování vztahů jednotlivých indikátorů s prediktory požáru byla datová sada testována v prostředí softwaru R, konkrétně R Studio (program pro statistické vyhodnocování dat). Modelování vztahu různých indikátorů se stejnou sadou prediktorů bylo provedeno lineární regresí a stepwise regresí pro nalezení nejvýznamnějších proměnných (prediktorů) ve vztahu k testovanému indikátoru.

Následující výsledky ukázaly na statistickou významnost modelu mezi závislou proměnnou indikátoru „TreeDWNsev“ (severitou postižení ležících stromů) a sadou prediktorů z obou sad dat DPZ (viz. Graf 11):


Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	1.79159	0.08775	20.416	< 2e-16	***
STD	0.08735	0.01502	5.815	8.59e-09	***
NDVIafter	-0.81445	0.20687	-3.937	8.93e-05	***
MEAN	-0.02433	0.01243	-1.958	0.0505	.
PCT90	-0.04506	0.02486	-1.813	0.0702	.

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1					
Residual standard error: 0.9883 on 849 degrees of freedom					
Multiple R-squared: 0.2737, Adjusted R-squared: 0.2703					
F-statistic: 79.99 on 4 and 849 DF, p-value: < 2.2e-16					

Hodnota indikátoru v případě, že jsou si všechny prediktory rovny je 1,79159. Tento koeficient je významný ($p < 2e-16$). R-squared činí 0,2703. Model ukázal, že jako nejvýznamnější vztahy se závislou proměnnou jsou prediktory „STD“ (směrodatná

odchylka), která patří do datasetu LiDAR a „NDVIafter“ (NDVI po požáru), z datasetu NDVI snímků.

Graf 11: Přehled korelací severity postižení ležících stromů s veličinami dat DPZ



Lepší výsledky se ukázaly při testování indikátoru „StanTreeSV“ (severita poškození stojících stromů) s prediktory z obou sad dat DPZ (stejně jako v předchozím případě).


Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	1.088047	0.109582	9.929	< 2e-16	***
MEAN	-0.077091	0.009480	-8.132	1.50e-15	***
STD	0.028765	0.018393	1.564	0.1182	
NDVIafter	-1.133833	0.255696	-4.434	1.05e-05	***
MIN	-0.012650	0.005835	-2.168	0.0304	*
NDVI dif	-0.550067	0.328509	-1.674	0.0944	.

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1					
Residual standard error: 0.9451 on 848 degrees of freedom					
Multiple R-squared: 0.394, Adjusted R-squared: 0.3904					
F-statistic: 110.2 on 5 and 848 DF, p-value: < 2.2e-16					

Přesnost modelu vyšla v případě indikátoru severity postižení stojících stromů R-squared 0,3904. Model ukázal, že jako nejvýznamnější vztahy se závislou proměnnou

jsou prediktory „MEAN“ (průměr), který patří do datasetu LiDAR a „NDVIafter“ (NDVI po požáru), z datasetu NDVI snímků. Z obou případů vyplývá, že nejlepších výsledků můžeme dosáhnout kombinováním obou typů dat DPZ. Výsledky testování dat s jinými indikátory byly ještě méně uspokojivé než zde uvedené.

Graf 12: Přehled korelací intenzity poškození ležících stromů s veličinami dat DPZ



Stejným způsobem byly testovány také proměnné intenzity poškození stojících a ležících stromů, ale výsledky této analýzy nebyly uspokojivé. Pro intenzitu poškození ležících stromů vyšla hodnota R squared 0,1586 a pro intenzitu poškození stojících stromů 0,1563.

4. 4. Výsledky modelů strojového učení

Vzhledem k nepříliš uspokojivým výsledkům regresní analýzy byla data podrobena analýze strojového učení, která patří mezi matematické modely se schopností predikce bez nutnosti programovat výpočty na míru konkrétní úlohy. Pro potřebu této práce byly použity dva modely strojového učení.

4. 4. 1. Výsledky modelu Random Forest (RF)

Datová sada byla bez předchozí přípravy podrobena výpočtům modelu strojového učení *Random Forest* s trojím opakováním a dvacetinásobnou křížovou validací. Výsledky modelu ukazují, s jakou přesností je model schopen na základě strojového učení předpovědět či klasifikovat určitá data.

Výsledky modelu pro severitu postižení stojících stromů (StanTreeSV) byla nejprve vyhodnocena s přesností 44,17 % a při druhém provedení výpočtu s výsledkem 44,12 %. Výstup modelu druhého provedení je uveden zde:

```
Random Forest
684 samples
 10 predictor

No pre-processing
Resampling: Cross-validated (20 fold, repeated 3 times)
Summary of sample sizes: 649, 649, 649, 651, 651, 652, ...
Resampling results across tuning parameters:

  mtry  RMSE      Rsquared  MAE
    2   0.9124399  0.4453939  0.7141487
    6   0.9189644  0.4383176  0.7143968
   10   0.9238506  0.4332027  0.7184434

RMSE was used to select the optimal model using the smallest value.
The final value used for the model was mtry = 2.

Length Class      Mode
call              4 -none-      call
type              1 -none-      character
predicted         684 -none-      numeric
mse               500 -none-      numeric
rsq               500 -none-      numeric
oob.times         684 -none-      numeric
importance        10 -none-      numeric
importanceSD      0 -none-      NULL
localImportance   0 -none-      NULL
proximity         0 -none-      NULL
ntree             1 -none-      numeric
mtry              1 -none-      numeric
forest           11 -none-      list
coefs             0 -none-      NULL
```

```

y                684    -none-    numeric
test             0      -none-    NULL
inbag            0      -none-    NULL
xNames           10     -none-    character
problemType      1      -none-    character
tuneValue        1      data.frame list
obsLevels        1      -none-    logical
param            0      -none-    list

rf variable importance

Overall
MEAN             100.000
SUM              90.712
MEDIAN           79.127
STD              67.624
MIN              39.055
NDVIbefore      37.634
NDVIafter       37.374
PCT90           19.645
RANGE           2.958
NDVIDif         0.000

Accuracy on testing data: 44.12%

```

Stejným způsobem byly provedeny výpočty a zobrazeny výsledky pro další indikátory, které jsou spolu s výsledky modelu uvedeny v tabulce 13, v níž jsou pro většinu indikátorů výsledky dvou provedení modelu RF. Z uvedených výsledků vyplývá, že každý proces výpočtů modelu je unikátní a výsledky se mohou lišit dokonce o cca 10 %.

Tabulka 13: Výsledky modelu Random Forest pro vybrané indikátory (model byl spuštěn dvakrát)

Random Forest	Accuracy on testing data (%)	
StandTreeSV	44,12	44,17
Streelnten	27,61	20,21
TreeDWNsev	39,20	33,82
TreeDWNint	21,62	29,29
KroviSev	36,00	35,11
KroviInt	6,67	8,80
KorunySev	23,12	33,33
HrankaRatio	0,00	1,15
HrankaIn	17,70	

4. 4. 2. Výsledky modelu Support Vector Machine (SVM)

Vzhledem k tomu, že ani model *Random Forest* nepřinesl příliš přesné výsledky, ačkoliv zlepšení predikce oproti regresní analýze poskytl, byla data testována odlišným modelem strojového učení *Support Vector Machine*.

SVM model byl použit s třemi typy Kernelů pro vyhledání predikce s nejvyšší přesností. Výsledky modelů pro severitu postižení stojících stromů byly následující:

1. SVM s Radial Basis Function (RBF)

```
Support Vector Machines with Radial Basis Function Kernel
704 samples
10 predictor
 5 classes: '0', '1', '2', '3', '4'

No pre-processing
Resampling: Cross-Validated (10 fold, repeated 3 times)
Summary of sample sizes: 633, 632, 634, 635, 635, 635, ...
Resampling results across tuning parameters:

  C          Accuracy   Kappa
  0.25      0.4913304  0.3282570
  0.50      0.4870442  0.3233452
  1.00      0.4803348  0.3156217
  2.00      0.4718866  0.3061987
  4.00      0.4670817  0.3015714
  8.00      0.4624071  0.2957935
 16.00      0.4377168  0.2650594
 32.00      0.4359205  0.2631562
 64.00      0.4159414  0.2376456
128.00      0.4061398  0.2264901

Tuning parameter 'sigma' was held constant at a value of 0.1557823
Accuracy was used to select the optimal model using the largest
value.
The final values used for the model were sigma = 0.1557823 and c =
0.25.

Length Class Mode
  1   ksvm   S4

Confusion Matrix and Statistics

      Reference
Prediction 0  1  2  3  4
      0  5  0  1  0  0
      1  5 44 19  6  3
      2  3  5 16 10  1
      3  1  3  7 14 12
      4  0  0  1  6 13
```

```

Overall Statistics

Accuracy : 0.5257
95% CI : (0.449, 0.6016)
No Information Rate : 0.2971
P-Value [Acc > NIR] : 2.318e-10

Kappa : 0.3708

McNemar's Test P-Value : NA

Statistics by Class:

Class: 0 Class: 1 Class: 2 Class: 3 Class: 4
Sensitivity 0.35714 0.8462 0.36364 0.3889 0.44828
Specificity 0.99379 0.7317 0.85496 0.8345 0.95205
Pos Pred Value 0.83333 0.5714 0.45714 0.3784 0.65000
Neg Pred Value 0.94675 0.9184 0.80000 0.8406 0.89677
Prevalence 0.08000 0.2971 0.25143 0.2057 0.16571
Detection Rate 0.02857 0.2514 0.09143 0.0800 0.07429
Detection Prevalence 0.03429 0.4400 0.20000 0.2114 0.11429
Balanced Accuracy 0.67547 0.7889 0.60930 0.6117 0.70017

```

Přesnost modelu s použitým RBF Kernelem činí 49,13 %

2. SVM s použitím lineárního Kernelu

```

Support Vector Machines with Linear Kernel

704 samples
10 predictor
5 classes: '0', '1', '2', '3', '4'

Pre-processing: centered (10), scaled (10)
Resampling: Cross-Validated (10 fold, repeated 3 times)
Summary of sample sizes: 633, 632, 634, 635, 635, 635, ...
Resampling results:

Accuracy Kappa
0.4990711 0.3427331

Tuning parameter 'C' was held constant at a value of 1

Length Class Mode
1 ksvm S4

```

Přesnost modelu s lineárním Kernelem činí 49,9 %

3. SVM s použitím polynomiálního Kernelu

```
Support Vector Machines with Polynomial Kernel

704 samples
10 predictor
5 classes: '0', '1', '2', '3', '4'

Pre-processing: centered (10), scaled (10)
Resampling: Cross-Validated (10 fold, repeated 3 times)
Summary of sample sizes: 633, 632, 634, 635, 635, 635, ...
Resampling results across tuning parameters:

degree  scale  C      Accuracy  Kappa
1       0.001  0.25  0.2983822  0.000000000
1       0.001  0.50  0.2988653  0.002906591
1       0.001  1.00  0.3366876  0.071441933
1       0.010  0.25  0.4437242  0.242355483
1       0.010  0.50  0.4548887  0.266780850
1       0.010  1.00  0.4619508  0.280548137
1       0.100  0.25  0.4932466  0.331909540
1       0.100  0.50  0.4989697  0.340839108
1       0.100  1.00  0.5000038  0.342710223
2       0.001  0.25  0.2993414  0.003733482
2       0.001  0.50  0.3371506  0.071996879
2       0.001  1.00  0.4128253  0.194335539
2       0.010  0.25  0.4567869  0.269150045
2       0.010  0.50  0.4638220  0.283430232
2       0.010  1.00  0.4904360  0.327218415
2       0.100  0.25  0.4892159  0.324334327
2       0.100  0.50  0.4891066  0.325254751
2       0.100  1.00  0.4925099  0.329860418
3       0.001  0.25  0.3139859  0.034369398
3       0.001  0.50  0.3772676  0.137057188
3       0.001  1.00  0.4526645  0.259531872
3       0.010  0.25  0.4567532  0.271223609
3       0.010  0.50  0.4824186  0.314614481
3       0.010  1.00  0.4942199  0.332683847
3       0.100  0.25  0.4838825  0.318366184
3       0.100  0.50  0.4871230  0.322972031
3       0.100  1.00  0.4866148  0.324257550

Accuracy was used to select the optimal model using the largest
value.
The final values used for the model were degree = 1, scale = 0.1
and C = 1.

Length      Class      Mode
1           ksvm      S4
```

Přesnost modelu s polynomiálním Kernelem činí 50,0%

Pro všechny zvolené indikátory proběhl stejný postup výpočtu i zobrazení výsledků. Přehled výsledků modelů pro tři použité Kernely je uveden v následující tabulce:

Tabulka 14: Výsledky modelu Support Vector Machine pro vybrané indikátory

Support Vector Machine			
Přehled základních výsledků v %			
	Kernels		
	RBF	Linear	Polynomial
StanTreeSV	49,13	49,91	50,00
TreeDWNsev	41,93	43,50	43,26
Streelnten	61,57	59,87	61,76
TreeDWNint	61,37	61,37	61,37
Hrabankaln	59,01	59,01	59,01
KroviInt	64,41	63,18	63,18
KroviSev	63,55	63,55	63,55
KorunyInt	44,09	42,58	43,63
KorunySev	44,68	44,12	44,12

Z přehledu výsledků vyplývá, že při použití Kernelu Radial Basis Function pro modelování intenzity postižení křoví (KroviInt) bylo dosaženo více jak 64 % přesnosti, což je ve srovnání s výsledky předchozích metod nejvíce (model Random Forest měl pro stejný indikátor přesnost 44,17 %).

5 DISKUSE

Metody DPZ se pro hodnocení intenzity lesního požáru ukázaly být vhodné pro monitorování následků požáru. Jejich vyhodnocení na datech týkajících se konkrétně Národního parku České Švýcarsko však ukázalo, že tyto metody přinášejí různá omezení a do problematiky vstupují určité podmínky.

Při prvotních analýzách dat, které proběhly v prostředí MS Excel bylo snahou zjistit základní vztahy mezi proměnnými datové sady. Přípravná analýza dat pozemní inventarizace odhalila, které faktory se navzájem nejvíce ovlivňují. Například intenzita poškození hrabanky úzce souvisí s intenzitou poškození ležícího stromu, což potvrzuje jinak celkem logicky dedukovatelnou souvislost. Zároveň ukázala i vztahy, které spolu příliš nekorelují. Například odečítaná hodnota procentuálního prohoření hrabanky z její celkové mocnosti se ukázala při korelačních analýzách jako bezvýznamná. Pro hrabanku byly hodnoty odečítány několika způsoby, z nichž jen intenzita poškození hrabanky se ve výsledcích ukazovala jako významná proměnná (tabulka 5 až 9).

Poměrně důležitý výsledek přinesla jednofaktorová ANOVA analýza s Tukeyho post hoc testem, které potvrdily, že typ lesa měl zásadní vliv na poškození požárem (graf 1).

Dále byly testy prováděny pro komparaci dat DPZ s referenčními daty pozemní inventarizace. Pro hodnocení typu lesa byl použit jako prediktor NDVI před a po požáru. Jak ukazuje krabicový graf 6, nejvíce se NDVI liší u živého lesa, zatímco mrtvý les a holina jsou si bližší. Mrtvý les má NDVI v obou případech nejnižší, což je dáno pravděpodobně tím, že přítomnost mrtvého dřeva zvyšuje podíl šedé barvy, zatímco na holině se snáze prosadí drobná vegetace, která NDVI zlepšuje.

Podobně byl hodnocen NDVI podle druhu dřeviny. Jak vyplývá z grafů 4 a 5, NDVI před požárem a po požáru se v závislosti na druhu dřeviny změnilo víceméně rovnoměrně, což poukazuje na to, že požár poškodil druhovou skladbu relativně podobně. To se odráží na tvaru krabicového grafu. Nicméně z jiných analýz vyplývá, že nejvíce náchylný k poškození je smrk (grafy 2 a 3). Jestliže však velké plochy smrkových porostů byly již před požárem zdecimované kůrovcovou kalamitou, požár nepředstavoval pro index NDVI po požáru tak markantní rozdíl. Naopak u mnohem vitálnějších porostů buku, ačkoliv jsou porosty plošně menší, představovalo poškození

požárem větší zásah do „zelenosti“ takových porostů, která má přímý vliv na stanovení NDVI. To by mohlo vysvětlovat, proč je tvar krabicového grafu pro NDVI před a NDVI po požáru podobný, ačkoliv z jiných výsledků vyplývá jasný rozdíl v náchylnosti dřevin. To zároveň poukazuje na jistá omezení metody hodnocení pomocí NDVI.

Při analýzách LiDAR datové sady s referenčními daty pozemní inventarizace se ukázaly být jako nejdůležitějšími prediktory proměnné MEAN – průměr a STD – směrodatná odchylka, zvláště ve vztahu k severitě poškození stojících stromů jako indikátoru (tabulka 11). Průměr představuje výškovou změnu na hodnocené ploše. Předpokládá se tedy, že tam, kde byla vysoká severita, tam také docházelo nejvíce k pádům stromů v důsledku síly hoření. Rovněž směrodatná odchylka měla vyšší korelaci. Ta představuje variabilitu/rozptyl výšek okolo střední hodnoty výšek stromů. To má přímou souvislost s pády stromů a změnou variability výšek na ploše. Výsledky analýzy LiDAR tedy poukazují na jisté zákonitosti, přestože velikost korelace není příliš vysoká. Je však zapotřebí brát v úvahu, že stromy na hodnocených plochách mohly spadnout i z jiné příčiny než z požáru. Vzhledem k tomu, že stav porostů na území NPČŠ byl horší již před požárem, lze tím vysvětlit řadu nepříliš uspokojivých výsledků.

Datová sada LiDAR byla také pro kontrolu srovnávána s datovou sadou NDVI (tabulka 12). Korelace MEAN a STD s NDVI before a NDVI after vycházely podobně, avšak pro NDVI before mírně vyšší. Naopak korelace rozdílového LiDAR s rozdílovým NDVI byla bezvýznamná. Výsledné hodnoty korelací blíží se 0,5 ukazují sice na závislost, ale nejsou příliš významné. Velikost shody ukazuje na vztah, kdy se předpokládá, že na plochách s výrazně záporným NDVI (velká severita) bude také vysoká hodnota MEAN nebo STD (z rozdílového LiDAR) představující změnu výšek a výškovou variabilitu. Tento vztah byl sice potvrzen, ale nedostatečně. Jak již bylo uvedeno, stav porostů na území NPČŠ byl natolik špatný již před požárem, že do analýz vstupují další a jen velmi těžko vyčíslitelné prediktory, které výsledky zkreslují.

Pokročilejšími analýzami byly modelové hodnoty lineární regrese a stepwise regrese. Výpočty pro některé indikátory byly značně nedostatečné. U analýzy s indikátory severity poškození stojících i ležících stromů a s datovou sadou proměnných z DPZ jakožto prediktory vyšly statisticky významné výsledky (graf 11, 12 a příslušné výstupy R skriptu). Tyto výsledky ukázaly jako nejdůležitější prediktory NDVI after,

MEAN a STD. Jak již bylo řečeno, samostatné použití NDVI anebo LiDAR přináší řadu omezení pro odhad intenzity poškození. Jak dokládají výsledky stepwise regresní analýzy, lze nejlepších výsledků dojít jedině kombinací těchto dvou metod DPZ, které fungují na zcela odlišných principech, a dokážou tak mnohem efektivněji předcházet chybám nebo nepochopení vstupních dat. Mezitím co metoda LiDAR nedokáže pracovat s vitalitou porostu, NDVI nedokáže pracovat s jeho prostorovým uspořádáním.

Pro jednotlivé indikátory (tabulka 13) byl vytvořen model Random Forest založený na metodě strojového učení. Ukázalo se totiž, že data nejsou vhodně uspořádána pro klasickou regresní analýzu. Metoda strojového učení byla tedy zvolena jako sofistikovanější alternativa s cílem dosažení přesnějších modelů. Nejvyšší přesnost modelu byla opět u severity postižení stojících a ležících stromů, avšak pohybovala se jen kolo 40 %. Nedostatečné výsledky RF ukazují na hlubší problém, který se může skrývat buď v uspořádání dat nebo v omezeních metod DPZ.

Z tohoto důvodu byla provedena odlišná metoda strojového učení Support Vector Machine. Modely pro jednotlivé indikátory (tabulka 14) byly již přesnější, a to až do 64 % podle indikátoru. I tyto výsledky jsou však neuspokojivé přihlédneme-li k podobným studiím (Benali et al., 2016, Gibson et al., 2020, Chafer et al., 2004) zmíněným v úvodu, a které dokonce pracovaly se satelitními snímky, jejichž přesnost by měla být obecně menší než u letadlových (Surový et al., 2019, Lillesand et al., 2015).

V případě dat z pozemní inventarizace můžeme uvažovat o jistých nedokonalostech, které se mohly propsat do výsledných kvalit modelů. Mezi ně teoreticky můžeme počítat odečítání hodnot pro severitu a intenzitu poškození v pěti kategoriích. Tyto hodnoty bychom mohli zpřesnit, pokud by byla stupni kategorií podrobnější nebo pokud by byly zaznamenány v konkrétních číslech jako „kvalifikovaný odhad“. Nicméně je potřeba brát v úvahu, že měření se účastnila celá řada osob s různou mírou znalostí a na inventarizaci byla omezená doba. Proto nebylo myslitelné proces inventarizace zatěžovat podrobnostmi, které by navíc nemusely být ve schopnostech pracovníků. Dalším faktorem by mohly být chybějící indikátory. Vzhledem k tomu, že NPCČŠ se nachází v oblasti labských pískovců, bylo by možné zaznamenávat míru poškození pískovcových útvarů (tato poškození byla v terénu skutečně přítomna), počet čerstvých zlomů stojících stromů na ploše, evidence stromů spadlých v důsledku požáru, podrobnější popsání druhové skladby apod.

Dalším faktorem, který ovlivnil přesnost provedené inventarizace byla lidská chybovost. Poměrně velké množství osob, které se na inventarizaci podílely byly v různé míře kvalifikovány a představa o významu jednotlivých proměnných se mohla lišit. V případě posuzování poškození hrabanky muselo být prováděno i více sond, protože i na malé ploše se prohoření hrabanky značně odlišovalo. V neposlední řadě hrála roli technika. K měření byla používána mobilní aplikace závislá na datovém připojení a GPS signál. Právě GPS lokalizace byla při měření zásadní, protože přesné souřadnice byly vyhledávány poměrně dlouhou dobu, a ne vždy byla plocha předem stanovená pomocí GIS vyhledatelná v terénu správně. Jak ukazuje obrázek 3, přesnost červených bodů (vytvořených člověkem v terénu) se na některých plochách výrazně liší od zelených bodů přesně určených GIS.

Datová sada NDVI obsahuje řadu informací, které na první pohled nemusí být zřejmé. Vedle NDVI před požárem a NDVI po požáru máme k dispozici také vypočítaný NDVI rozdílový. Jeho velikost představuje změnu, která na ploše proběhla mezi dvěma časy pořízení dat. Tato změna tedy ukazuje na velikost potenciální severity a intenzity požáru na ploše. Navzdory této úvaze ukázaly analýzy, že nejvyšších shod dosahujeme při analýzách, do kterých jako prediktory vstupují NDVI před požárem a po požáru. V samotné číselné hodnotě NDVI je totiž obsažena informace o vitalitě porostu. Proto lze snadno odvodit, v jakém stavu byl porost před požárem i po požáru. A právě tyto informace nám také říkají, že porost již před požárem vykazoval velice nízké hodnoty NDVI. Vedle toho, že takový porost je náchylnější na šíření požáru, představuje tato nízká hodnota problém v matematických modelech, kdy navzdory silnému lesnímu požáru se „šedivost“ a „černost“ vyhodnocovaných pixelů nezmění o tolik, kolik by bylo adekvátní síle požáru. To zprvé vysvětluje nepřiliš přesné výstupní modely, za druhé poukazuje na nedostatečnost této metody minimálně v některých případech a vyžaduje zahrnutí zcela odlišné metody, jak již bylo uvedeno výše (v případě této práce LiDAR).

Stojící mrtvé stromy představují ve vyhodnocování NDVI zkreslení, protože vytváří na snímcích rozsáhlé plochy šedé barvy. Jak dokázaly výsledky této práce, i holina potenciálně porostlá drobnou vegetací vyazuje vyšší NDVI. Právě rozsáhlé plochy souší zřejmě zásadně ovlivnily data a následnou tvorbu matematických modelů. V roce 2018 bylo v NPCŠ celkem 500,19 ha souší bez holin a ces. Následně se množství zdvojnásobilo na 1302,29 ha v roce 2019. V roce 2022, kdy NPCŠ zasáhl

Výsledky stepwise regrese následně jasně potvrdily předchozí tvrzení, že nejlepších modelů je možné dosáhnout jedině kombinací metod DPZ. Nejlepší prediktory se ukázaly být NDVI after, což představuje vcelku logický vztah mezi hodnotou vyjadřující stav po požáru s poškozením požárem. Dále to byla směrodatná odchylka a průměr LiDAR, které rovněž zachycují prostorovou variabilitu a změny na plochách. Jak již ale bylo řečeno, do dat vstupuje určitá chybovost a nedokonalost metod, navíc různorodost proměnných v datových sadách jejichž vzájemné vztahy nemusí nutně nejlépe fungovat pro lineární regresi na níž je postavena stepwise regrese postupného přidávání a ubírání prediktorů tak, aby model vybral nejdůležitější proměnné a nebyl příliš složitý.

Pro přesnější modelování byla zvolena metoda strojového učení Random Forest a Support Vector Machine, kde každá funguje na odlišném principu (viz Metodika). Výsledky Random Forest přinesly oproti Stepwise regresi mírné zlepšení. Závěrečný model SVM pak dosáhl nejvyšší přesnosti z dosud použitých modelů. Tato přesnost (i více jak 64 %) není sice natolik vysoká, abychom na základě modelu byli schopní kategorizovat poškození požárem do konkrétních stupňů a podrobně ho popsat, ale již dokážeme říci, kde například hořelo více a kde méně. Nízká přesnost modelu oproti zmíněným studiím však poukazuje na předchozí tvrzení, tj. že do dat vstupují nežádoucí prvky, chyby, roční období, data pořízení snímků, podrobnost inventarizace, způsob, jakým jsou vyjádřeny proměnné atp. Oba modely strojového učení však umožňují další zpřesňování například pomocí důkladnější přípravy dat, křížových validací mezi modely apod. Lze tedy hledat ještě sofistikovanější způsoby na platformě statistiky.

Teoreticky nejlepším způsobem vyhodnocení a tvorby modelů se pro data tohoto typu zdá být umělá inteligence, která, ačkoliv je s metodami strojového učení příbuzná, je schopna automaticky identifikovat vztahy a jiné složité vzorce v datech bez nutnosti předem definovat modely. Tato metoda poskytuje vedle modelování vztahů také automatické učení a predikční schopnosti.

6 ZÁVĚR

Tato práce se zabývala analýzou materiálů dálkového průzkumu Země a možností tvorby matematických modelů pro vyhodnocování intenzity lesního požáru v Národním parku České Švýcarsko, který se odehrál roku 2022. Na základě referenční inventarizace byly stanoveny indikátory, které byly postupně testovány jak ve vztazích mezi sebou, tak s daty DPZ pasivních a aktivních senzorů, tj. senzory blízkého infračerveného záření a z něj vypočteného NDVI a aktivních senzorů LiDAR. Oba typy dat DPZ byly pořízeny z letadla pro vyšší přesnost. Následně byly provedeny analýzy jako je korelační analýza, ANOVA analýza, lineární regrese a stepwise regrese pro tvorbu modelů kde jako indikátory byly vybrány proměnné inventarizace a jako prediktory vybrané závislé proměnné z obou datasetů DPZ. Pro pokročilejší modelování byly použity metody strojového učení Random Forest a Support Vector Machine.

Výsledkem práce je popis nejvýznamnějších vztahů proměnných v lesním požáru, a především modely pro stanovení intenzity požáru z nichž Support Vector Machine vykazoval nejpreciznější výsledky (až 64,4 %). Výsledky s nepříliš velkou přesností zároveň poukázaly na významný vliv prostředí, které je hodnoceno, na kvalitu vstupních dat, ale také na možnosti tyto modely dále vylepšovat a hledat pokročilejší metody tvorby modelů.

Výstupy práce poukazují na potřebu lepšího předzpracování dat a na zásadní vliv prostředí, kde v některých případech mohou metody hodnocení pomocí DPZ vykazovat vysokou přesnost, jindy však v závislosti na přírodních podmínkách a jiných faktorech relativně nižší.

Pro praktické použití je tedy prozatím nezbytné pořizování alespoň částečné inventarizace skutečného stavu požářiště, a to jak pro zpřesnění modelů pro konkrétní prostředí, tak pro obecnou znalost prostředí. Některé materiály DPZ totiž teoreticky mohou zkreslovat intenzitu požáru a podhodnocovat ho.

LITERATURA

ADÁMEK, Martin; BOBEK, Přemysl; HADINCOVÁ, Věroslava; WILD, Jan a KOPECKÝ, Martin. Forest fires within a temperate landscape: A decadal and millennial perspective from a sandstone region in Central Europe. Elsevier. 2014, s. 10.

ADÁMEK, Martin; JANKOVSKÁ, Zuzana; HADINCOVÁ, Věroslava; KULA, Emanuel a WILD, Jan. Drivers of forest fire occurrence in the cultural landscape of Central Europe. Springer Nature. 2018, s. 15.

ADÁMEK, Martin. Požár jako ekologický faktor v lesích střední Evropy. Autoreferát disertační práce. Praha: Univerzita Karlova v Praze, Přírodovědecká fakulta Katedra Botaniky, 2016.

Benali, Akli, et al. "Determining fire dates and locating ignition points with satellite data." *Remote Sensing* 8.4 (2016): 326.

BERČÁK, Roman et al. LESNÍ POŽÁRY V ČESKÉ REPUBLICE – CHARAKTERISTIKA, PREVENCE A HAŠENÍ: REVIEW. Zprávy lesnického výzkumu. 2018, roč. 63, č. 3, s. 11.

BOBEK, Přemysl; TRNKA, Miroslav; KUDLÁČKOVÁ, Lucie; PODĚBRADSKÁ, Makéta; BLÁHOVÁ, Monika et al. Jaké faktory ovlivnily vznik a šíření požáru v NP České Švýcarsko? S. 113. 2022.

GIBSON, Rebecca, Tim Danaher, Warwick Hehir, Luke Collins, A remote sensing approach to mapping fire severity in south-eastern Australia using sentinel 2 and random forest, *Remote Sensing of Environment*, Volume 240, 2020.

Chafer, Chris J., Mark Noonan, and Eloys Macnaught. "The post-fire measurement of fire severity and intensity in the Christmas 2001 Sydney wildfires." *International Journal of Wildland Fire* 13.2 (2004): 227-240.

Korpela, I.; Mehtatalo, L.; Markelin, L.; Seppanen, A.; Kangas, A. Tree species identification in aerial image data using directional reflectance signatures. *Silva Fenn.* 2014, 48, 1087

Kuhn, M. 2019. The Caret Package. <https://topepo.github.io/caret/index.html>.

Lillesand, T. M., Kiefer, R. W., Chipman, J. W. (2015). *Remote Sensing and Image Interpretation*. 7th ed. New York: John Wiley. ISBN 978-1-118-343-289.

MANJREKAR, Onkar a DUDUKOVIĆ, Milorad. Identification of flow regime in a bubble column reactor with a combination of optical probe data and machine learning technique. Online. *Research Gate*. 2019, s. 11. Dostupné z: <https://doi.org/10.1016/j.cesx.2019.100023>. [cit. 2024-04-04].

NÁRODNÍ PARK ČESKÉ ŠVÝCARSKO. Online. Správa Národního parku České Švýcarsko. Dostupné z: <https://www.npcs.cz/>. [cit. 2024-04-03].

ONDRUŠKOVÁ, Alena. *Odhad postupu kůrovcové gradace v Národním parku České Švýcarsko pomocí metod Dálkového průzkumu Země*. Diplomová práce. Praha: Česká zemědělská univerzita v Praze, 2023.

STATISTICKÁ ROČENKA Hasičského záchranného sboru České republiky 2022.
Praha, 2022.

SUROVÝ, Peter, Karel KUŽELKA, Azadeh ABDOLAHNEJAD, Kateřina SIROTKOVÁ, Zlatica MELICHOVÁ a Martin SLAVÍK, 2019. Aplikace dálkového průzkumu Země v lesnictví. B.m.: ČZU v Praze, Fakulta Lesnická a Dřevařská. ISBN 8001015971.