

Česká zemědělská univerzita v Praze

Fakulta lesnická a dřevařská

Detekce kloubnatky smrkové – *Gemmamyces piceae* (Borthw.) Casagr., pomocí
analýzy obrazu

Diplomová práce

Autor: Bc. Kristián Farárik

Vedoucí: Ing. Roman Modlinger, Ph.D.

2022

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta lesnická a dřevařská

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Kristián Farárik

Lesní inženýrství

Lesní inženýrství

Název práce

Detekce kloubnatky smrkové – *Gemmamyces piceae* (Borthw.) Casagr., pomocí analýzy obrazu.

Název anglicky

Detection of the bud blight *Gemmamyces piceae* (Borthw.) Casagr., by image analysis method.

Cíle práce

Cílem diplomové práce je pořídit obrazový materiál s napadenými pupeny kloubnatkou smrkovou – *Gemmamyces piceae* (Borthw.) Casagr., elektronicky označit napadené a nenapadené pupeny, asistovat při tvorbě algoritmu obrazové detekce, který bude schopen rozeznávat napadené a nenapadené pupeny. Posoudit možnosti použití analýzy obrazu v detekci lesních škodlivých činitelů.

Metodika

Na vybrané lokalitě v Krušných horách bude pomocí fotoaparátu bezpilotního prostředku pořízen obrazový materiál s pupeny napadenými kloubnatkou smrkovou – *Gemmamyces piceae* (Borthw.) Casagr., a pupeny zdravými. Primárním cílem detekce bude smrk pichlavý – *Picea pungens* Engelm. V programu Labelling budou na fotografiích identifikovány pupeny jednoznačně napadené a zdravé. Výsledný soubor označených pupenů musí obsahovat alespoň 1000 identifikovaných záznamů od každé varianty. Soubor fotografií s identifikovanými pupeny bude rozdělen na trénovací a validační sadu v poměru 3:1. Pro vytvoření klasifikace objektů bude využito platformy TensorFlow deep learning (Abadi et al., 2015). Přesnost klasifikačního algoritmu bude statisticky ověřena pomocí F1 skóre (správný výsledek, chyba I a chyba II druhu).

Harmonogram:

červenec 2021 – výběr vhodných stromů a nasnímání objektů

srpen 2021 – rozpoznávání napadených a nenapadených pupenů

září až listopad 2021 – identifikace pupenů na obrazovém materiálu

prosinec až leden – učení algoritmu

leden až březen – vyhotovení práce

Diplomová práce bude zpracována ve slovenštině.

Doporučený rozsah práce

50-70 stran

Klíčová slova

TensorFlow, deep learning, Fytopatologie, Ochrana lesa, DPZ, smrk, damage

Doporučené zdroje informací

- ABADI, M., et al. TensorFlow: A system for large-scale machine learning. Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI '16), November 2–4, 2016 Savannah, GA, USA, 1–21. ISBN 978-1-931971-33-1
- ČERNÝ, K.; PEŠKOVÁ, V.; SOUKUP, F.; HAVRDOVÁ, L.; STRNADOVÁ, V.; ZAHRADNÍK, D.; HRABĚTOVÁ, M. Gemmamyces bud blight of Picea pungens: a sudden disease outbreak in Central Europe. Plant Pathology, 2016, 65 (8): 1267-1278.
- SENF, C., SEIDL, R., HOSTERT, P., 2017. Remote sensing of forest insect disturbances: current state and future directions. Int. J. Appl. Earth Obs. Geoinf. 60, 49–60.
- SOUKUP, F.; PEŠKOVÁ, V. Gemmamyces piceae (Borthw.) Casagr. kloubnatka smrková. Lesní ochranná služba, Výzkumný ústav lesního hospodářství a myslivosti, Praha, 2009, 4 s.
- SUROVÝ, P.; KUŽELKA, K.; ABDOLAHNEJAD, A.; SIROTKOVÁ, K.; MELICHOVÁ, Z.; SLAVÍK, M. Aplikace dálkového průzkumu Země v lesnictví. FLD, Praha, 2019, 240 s.
- ZÝKA, V.; ČERNÝ, K.; STRNADOVÁ, V.; HRABĚTOVÁ, M.; HAVRDOVÁ, L.; ROMPORTL, D. Predikce poškození porostů smrku pichlavého kloubnatkou smrkovou v Krušných horách. Mapa s odborným obsahem, VÚKOZ, v. v. i. Certifikováno Ministerstvem zemědělství ČR. VÚKOZ, v. v. i., Průhonice, 2018, 48 s.

Předběžný termín obhajoby

2021/22 LS – FLD

Vedoucí práce

Ing. Roman Modlinger, Ph.D.

Garantující pracoviště

Excelentní tým pro mitigaci

Konzultant

Priv.-Doz. Ing. Peter Surový, PhD

Elektronicky schváleno dne 10. 7. 2020

prof. Ing. Marek Turčáni, PhD.

Vedoucí ústavu

Elektronicky schváleno dne 18. 10. 2020

prof. Ing. Róbert Marušák, PhD.

Děkan

V Praze dne 30. 03. 2022

Čestné prehlásenie:

Prehlasujem že som diplomovú prácu na tému Detekce kloubnatky smrkové – *Gemmamyces piceae* (Borthw.) Casagr., pomocí analýzy obrazu vypracoval samostatne pod vedením Ing. Romana Modlingera, Ph.D., a použil len pramene ktoré uvádzam v zozname použitých zdrojov. Som si vedomí, že zverejnením diplomovej práce súhlasím s jej zverejnením podľa zákona č. 111/1998 Sb. O vysokých školách v platnom znení, a to bez ohľadu na výsledky jej obhajoby.

V deň

Podpis autora:

Pod'akovanie:

Moje pod'akovanie patri Ing. Romanovi Modlingerovi, Ph.D., za odborné vedenie práce, poskytnuté materiály a cenné rady, ktoré mi pomohli túto prácu skompletizovať. Taktiež d'akujem Ing. Alexandrovi Mrázovi, PhD. a Ing. Michalovi Samkovi za odborné konzultácie a rady pri zhotovovaní diplomovej práce. Chcel by som sa pod'akovať aj mojim priateľom a rodine, ktorý pri mne stály počas celého štúdia.

Abstrakt

V 70. a 80. rokoch minulého storočia boli Krušohorské lesy pripravené o väčšinu svojich pôvodných smrekových porastov z dôvodu silného imisného znečistenia. Tieto porasty boli nahradené náhradnými druhmi drevín. Jednou s týchto drevín bol aj smrek pichľavý (*Picea pungens* Engelm.), na ktorom bol zavlečený hubový patogén klubnatka smreková (*Gemmamyces piceae* (Borthw.) Casagr.), čo malo a stále má následok odumieranie jedincov tohto druhu dreviny. Cieľom tejto práce bolo vytvoriť a testovať nový algoritmus založený na princípe analýzi obrazu so zameraním práve na *G. piceae* (Borthw.) Casagr.. Trénovanie a testovanie tohto algoritmu prebiehalo na snímkach rozdelených v pomere 80 % pre trénovanie a 20 % pre testovanie. Zo zistených výsledkov pomocou štatistickej metódy Precision, Recall a F1 score bola zistená viac než 50 % úspešnosť pri identifikácii patogénu. Z tohto možno konštatovať pomerne uspokojivé výsledky, no vzhľadom k tomu, že sa jedná iba o alpha verziu algoritmu bude ešte potreba ďalších rozsiahlejších výskumov a postupov.

Kľúčové slová: Fytopatológia, ochrana lesa, diaľkový prieskum zeme, smrek, TensorFlow, Deep learning, poškodenie

Abstract

In the 70's and 80's of the last century, the Ore Mountains forests were deprived of the most of their original spruce stands due to heavy air pollution. These stands have been replaced by replacement tree species. One of these trees was the Norway spruce (*Picea pungens* Engelm.), on which the fungal pathogen *Gemmamyces piceae* (Borthw.) Casagr., was introduced, which had and still effects results in the deaths of individuals of this species. The aim of this work was to create and test a new algorithm based on the principle of image analysis with focus on *G. piceae* (Borthw.) Casagr. Training and testing of this algorithm took place on images divided at a ratio of 80 % for training and 20 % for testing. More than 50 % success in identifying the pathogen was found from the results obtained using the statistical method Precision, Recall and F1 score. This shows relatively satisfactory results but since it is only the alpha version of the algorithm more extensive research and procedures will be needed.

Key words: Phytopathology, Forest Pest Management, Remote Sensing, spruce, TensorFlow, Deep learning, damage

Obsah

1. Úvod	12
2. Rozbor problematiky	13
2.1. Popis Krušných hôr a ich súčasná situácia.....	13
2.2. Porasty náhradných drevín Krušných hôr.....	14
2.2.1. Smrek pichľavý (<i>Picea pungens</i>).....	15
2.3. Významné patogény Krušných hôr.....	15
2.3.1. Klubnatka smreková (<i>Gemmamyces piceae</i>).....	16
2.4. DPZ.....	17
2.4.1. Družice.....	18
2.4.2. Lietadlá.....	19
2.4.3. Bezpilotné lietadlá a drony.....	20
2.5. Deep learning.....	21
2.5.1. Konvolučné neurónové siete (Convolutional Neural Network).....	21
2.5.2. TensorFlow.....	23
2.5.3. MobilNet.....	25
2.5.4. Object based image analysis.....	26
3. Metodika	27
3.1. LabelImg.....	29
3.2. Parametre algoritmu a prehľadová tabuľka počtov obrázkov a objektov...	30
3.3. Štatistické vyhodnotenie.....	32
3.4. R software.....	34
3.5. Výstupy XML súborov.....	34
3.6. Evaluácia XML súborov podľa kategórií chybovej matice.....	35
4. Výsledky	37
4.1. Výstupy softwaru R.....	38
4.1.1. Výsledky výpočtu hodnoty Precision.....	38
4.1.2. Výsledky výpočtu hodnoty Recall.....	40
4.1.3. Výsledky výpočtu hodnoty F1 score.....	42
5. Diskusia	44
6. Záver	46
7. Zoznam použitej literatúry	47
8. Prílohy	54

Zoznam obrázkov, tabuliek a grafov:

Zoznam obrázkov

Obr. 1. Životný cyklus <i>G. piceae</i>	17
Obr. 2. Spracovanie údajov pomocou CNN.....	21
Obr. 3. Príklad jednoduchého výpočtového grafu a komplexného výpočtového grafu pre TensorFlow.....	23
Obr. 4. Kombináciou premennej v nezmenenej podobe (i) a premennej, ktorá nesie mutačnú informáciu (v) vznikne výsledná požadovaná premenná potrebná pre vytváraný algoritmus.....	24
Obr. 5. Vizuálne vyobrazenie hĺbkovej konvolúcie.....	26
Obr. 6. Vizuálne vyobrazenie bodovej konvolúcie.....	26
Obr. 7. Lokalita v ktorej sa vykonával výskum je vyznačená na mape zeleným bodom.....	27
Obr. 8. DJI Mavic 2.....	28
Obr. 9. DJI Phantom 4 Pro.....	28
Obr. 10. LabelImg vyznačovanie údajov s rozdelením napadnutých a nenapadnutých púčikov.....	30
Obr. 11. LabelImg snímky po druhotnom spracovaní pre TensorFlow.....	30
Obr. 12. Vzor chybovej matice pre binárnu klasifikáciu.....	33
Obr. 13. XML výstup modelu.....	35
Obr. 14. Vzor výstupov tabuliek s určením kategórií chybovej matice.....	36
Obr. 15. Graf s minimálnou presnosťou Thresholdu 30 %.....	37
Obr. 16. Graf s minimálnou presnosťou Thresholdu 50 %.....	37
Obr. 17. Kódovanie použité pre výpočet Precision.....	39
Obr. 18. Grafické prevedenie výsledkov Precision.....	40
Obr. 19. Kódovanie použité pre výpočet Recall.....	40
Obr. 20. Grafické prevedenie výsledkov Recall.....	41
Obr. 21. Kódovanie použité pre výpočet F1 score.....	42
Obr. 22. Grafické prevedenie výsledkov F1 score.....	43

Zoznam tabuliek

Tab. 1 Parametre použitého hardwaru.....	37
Tab. 2 Prehľad počtov obrázkov a objektov.....	38
Tab. 3. Hodnoty zistené po výpočte Precision.....	40
Tab. 4. Hodnoty zistené po výpočte Recall.....	41
Tab. 5. Hodnoty zistené po výpočte F1 score.....	42

Zoznam skratiek

AI	Artificial intelligence
DPZ	Dialkový prieskum zeme
ALS	Aerial Laser Scanning
UAV	Unmanned Aerial Vehicles
RPAS	Remotly Piloted Aerial System
DL	Deep learning
UNS	Umelá neurónová sieť
CNN	Convolutional Neural Network
GPU	Graphic Processing Unit
OBIA	Object Base Image Analysis
CPU	Central Processing Unit
TP	True Positive
FP	False Positive
TN	True Negative
FN	False Negative

1. Úvod

Krušné hory vplyvom imisnej a kôrovcovej kalamity v 70. a 80. rokoch minulého storočia stratili takmer všetky pôvodné staré smrekové porasty. Tieto porasty boli však nahradzované porastmi náhradných drevín, čo ale neskôr viedlo k ďalším komplikáciám pri snahe opätovného zalesňovania Krušných hôr. Introdukovaním nepôvodných druhov drevín došlo aj k zavlečeniu nepôvodných patogénov.

Táto diplomová práca bola vybraná na základe súčasného stavu Krušných hôr a rozšírení nepôvodného patogénu klubnatky smrekovej (*Gemmamyces piceae* (Borthw.) Casagr.) na introdukovanom smreku pichľavom (*Picea pungens* Engelm.). Tento patogén spôsobuje deformácie púčikov smreku a spôsobuje rozsiahle odumieranie *P. pungens* v tejto prírodnej lesnej oblasti. Ďalším dôvodom pre výber tejto práce bol súčasný rýchly vývoj a praktické využitie DPZ a AI, či už v biologicky zameraných alebo iných vedných oboroch.

Diplomová práca bola zameraná na vytvorenie nového algoritmu, ktorý bude možnosť využiť pri DPZ a pomôže uľahčiť a urýchliť identifikáciu jedincov napadnutých *G. piceae*. Výstupy tejto práce by mali určiť úspešnosť alpha verzie tohto algoritmu. Údaje, ktoré budú uvádzané v diplomovej práci môžu byť neskôr využité pri dokončení programu a jeho plnom využití pri práci v teréne.

2. Rozbor problematiky

2.1 Popis Krušných hôr a ich súčasná situácia

Prírodná lesná oblasť Krušné hory sa rozprestiera na ploche o dĺžke 130 km zo severovýchodu na severozápad a široké iba v rozmedzí 6 -19 km na českej strane (SMEJKAL, 2002). Hranice Krušných hôr sú presne definované podľa vyhlášky č. 83/1996 Sb., príloha č.1., keďže sa rozprestierajú aj na nemeckej strane.

Krušné hory tvoria náhorné plošiny uklonené k severozápadu väčšinou v rozmedzí 700 – 1000 m. n. m. a príkre zlomové svahy orientované k juhovýchodu do podkrušnohoria. Najvyššie položenou oblasťou Krušných hôr je Klínovecká oblasť s najvyšším vrcholom Klínovec (1243 m. n. m.).

Krušné hory je možné rozdeliť na tri hlavné oblasti a to juhozápadnú, strednú a severovýchodnú. Každá oblasť sa líši svojím reliéfom a výškovým rozpožčením.

Stredná a juhozápadná časť Krušných hôr sú oddelené hranicou medzi Pernštejncom a Vykmanovom, Kovařskou a českými Hamry. Hranicou medzi strednou a severovýchodnou časťou Krušných hôr je línia tvorená Krupkou, Hornou Krupkou a Fojtovicami (DEMEK et al., 1965).

Rozloha lesa v sa pohybuje okolo 115 km² s prevahou spoločenstiev kyslých smrekovo bukových, bukovo smrekových a jedľovo bukových LVS. V oblasti sú však menej zastúpené svieže smrekové bučiny, jedľové bučiny, podmáčané a rašelinové smrečiny. Aj napriek tomu je na menších plochách svahov možné nájsť bohato zastúpené lesné typy od dubovo bukových po smrekové LVS (PRŮŠA, 2001).

V druhej polovici 80. rokov minulého storočia boli v oblasti Krušných hôr spôsobené rozsiahle imisné poškodenia oxidom siričitým, ktorý bol počas zimných mesiacov sprevádzaný taktiež vysokými koncentraciami fluorovodíku. Práve zimné obdobie a koncentrácia oxidu siričitého v kombinácii s fluorovodíkom boli hlavným dôvodom imisných ťažieb v sedemdesiatych a osemdesiatych rokoch (ŠRÁMEK, 1998). Od polovice 90. rokov však dochádzalo k poklesu imisnej záťaž vďaka zníženiu množstva hlavných zdrojov a to tepelných elektrární a priemyselnej výroby s nahradzovaním novými technológiami (LOMSKÝ & ŠRÁMEK, 2004).

Ako bolo vyššie spomenuté rozsiahle imisné poškodenie viedlo k ťažbe pôvodných porastov, ktoré boli nahradené, náhradnými druhmi drevín ako *Sorbus aucuparia* L. (LOCHMAN et al., 2008) alebo *P. pungens* (KUBELKA et al., 1992).

P. pungens bol do tejto oblasti introdukovaný už na začiatku minulého storočia. Jeho introdukovaním boli do Krušných hôr zavlečené nepôvodné patogény, ktoré začali napádať aj pôvodné druhy smrekov. Začiatkom 21. storočia začali smreký vykazovať rýchly a pomerne veľký nárast napadnutia patogénom *G. piceae* tiež známym ako klubnatka smreková. Napadnutia týmto patogénom boli zaznamenané už počas začiatku minulého storočia, no poškodenia neboli natoľko vážne aby sa ďalej o tomto patogénne viedli záznamy (PEŠKOVÁ et al., 2019).

2.2 Porasty náhradných drevín Krušných hôr

Náhradné porasty drevín v Krušných horách začali vznikať v období 70. rokov kedy boli Krušné hory silno poškodené imisiami. Tieto dreviny mali slúžiť dočasná náhrada za poškodené smrekové monokultúry. Dočasnou náhradou boli hlavne, pretože nezaistovali všetky potrebné ekologické funkcie. Za týmto účelom boli vysadené náhradné dreviny rodov ako *Betula* spp., *Sorbus aucuparia* L. a *P. pungens*, ktoré mali za úlohu pomôcť vytvoriť priaznivejšie podmienky pre rast a obnovu pôvodných porastov (LOMSKÝ et al., 2007). Listnaté dreviny mali za úlohu zlepšiť pôdne podmienky a pripraviť porast zatiaľ čo ihličnaté dreviny mali slúžiť ako čiastočná náhrada za zníženú produkciu.

Aj napriek snahám o obnovu sa po vysadení náhradných drevín začali vyskytovať nové druhy škodcov na drevinách. Týmto problémom bola venovaná veľká pozornosť v prácach ako napríklad BALCAR et al. (2008), PEŠKOVÁ & SOUKUP (2013) alebo PEŠKOVÁ & MODLINGER (2014). Hlavnou a najohrozenejšou drevinou ktorá od 70. rokov bola rozsiahle napadnutou svojim pôvodným škodcom bola introdukovaná drevina *P. pungens* patogénom *G. piceae*. Pri výskumoch z roku 2013 a 2014 boli taktiež napríklad zistené výrazné poškodenie *Larix decidua* Mill. hmyzími biotickými škodcami ale brvenkou *Lachnellula willkommii* (Hartig) Dennis (BALCAR et al., 2015).

2.2.1. Smrek pichľavý (*Picea pungens*)

Z hľadiska plošného rozloženia v oblasti Krušných hôr je smrek pichľavý druhov najrozšírenejšou drevinou v prírodnej lesnej oblasti. S súčasnej dobe zaujíma rozlohu väčšiu ako 8000 ha (BALCAR et al., 2015).

Jedná sa o nepôvodnú drevinu introdukovanú zo Severnej Ameriky z oblasti Rocky Mountains v západnej časti USA. *P. pungens* vo svojej pôvodnej oblasti výskytu obyčajne rastie vo vyšších nadmorských výškach s vyšším stupňom vlhkosti a nižšou teplotou (BALLARD et al., 1985).

Aj napriek preferencii tohto druhu na vlhkosť dokáže *P. pungens* odolávať suchu omnoho lepšie než ostatné druhy smrekov (ČERNÝ, 2016). Dokáže rásť na všetkých druhoch stanovíšť, no najviac vyhovujú dobré, hlboké, ílovité pôdy na otvorených, prípadne mierne zatienených stanoviskách. Vďaka svojmu pôvodu dokáže tento druh smreku odolávať teplotným zmenám až do - 40°C (STRNADOVÁ et al., 2006).

P. pungens bol v polovici minulého storočia najčastejšie používanou drevinou na opätovné zalesnenie a náhradu pôvodných smrekových porastov v oblasti Krušných hôr a Krkonoš a to hlavne z dôvodu odolnosti voči kyslým dažďom po znečistení a zničení lesov oxidom siričitým v druhej polovici minulého storočia (HAWKSWORTH et al., 1972).


2.3 Významné patogény Krušných hôr

Hlavným introdukovaným ihličnanom určeným na obnovu smrekových porastov bol *P. pungens*. Najvýznamnejšími patogénmi nájdenými na tejto drevine sú *Gemmamyces piceae*, *Sirococcus conigenus* (DC.) P. Cannon & Minter a *Lophodermium piceae* (Fuckel) Hohn. (PEŠKOVÁ et. MODLINGER, 2015). Ďalšou drevinou vyskytujúcou sa v Krušných horách je *Larix decidua*, ktorá býva napádaná patogénom *Lachnellula willkommii* (Hartig) Dennis. *Pinus mugo* Turra a *Pinus rotundata* obyčajne bývajú napadnuté sypavkami rodu *Lophodermium* Chevall., no v ojedinelých prípadoch sa objavuje vzácne napadnutie hubou *Gremmeniella abietina* (Lagerb.) M. Morelet (BALCAR et al., 2015).

2.3.1. Klubnatka smreková (*Gemmamyces piceae*)

G. piceae, synonymum *Cucurbitaria piceae* (Borthw.) Petr. sa už od počiatku minulého storočia začala vyskytovať v Európe, presnejšie v Škótsku, na smreku pichľavom (BALLARD et al., 1985). Jedná sa o pomerne chladnomilný druh hubového patogénu, ktorý môže mať pre strom až fatálne následky. Podľa taxonomického zaradenia *G. piceae* patrí do oddelenia *Acsomycota*, radu *Pleosporales* a čeľade *Melanommataceae* (JAKLITSCH et. VOGLMAYR, 2017). Tento druh huby je schopný rásť v teplotnom rozmedzí od 0°C až do maxima 25°C, čo jej umožňuje sa šíriť aj vo vyšších nadmorských výškach (PETRZIK et al., 2016).

Smrek napadá v letných mesiacoch pričom dominantným spôsobom, ktorým infikuje jedincov sú konídie (ČERNÝ et al., 2016). V podobe hýf, prípadne aj v pohlavnom štádiu patogén prežíva v púčikoch do jari. Nálezy boli zistené už v Apríli. Niekedy sa následky napadnutia môžu preukazovať na púčikoch v podobe zčernania špičky už behom jesene. V období mája sa lézie v púčikoch začínajú zväčšovať a behom vlhších dní môžu byť pokryté bielym mycéliom. Po infikovaní dochádza k následnému odumieraniu púčikov čo vedie k ich deformácii. Túto deformáciu je možné na strome pozorovať typickým zakrútením púčikov ku ktorému dochádza ak sa púčik snaží o rašenie. Napadnuté stromy v nasledujúcich rokoch na patogén reagujú zvýšenou tvorbou adventných púčikov, ktoré sú neskôr znova napádané. Vetvenie stromu má po určitej dobe charakteristický kostřbatý vzhľad z dôvodu periodického odumierania terminálnych púčikov. Od júna sa následne na mŕtvych púčikoch začínajú vytvárať pyknidy ktoré produkujú veľké množstvo konídií. Ku kulminácii konídií dochádza v júly s postupným klesaním ku koncu septembra. V období decembra môžeme pozorovať pomalý vývoj základov pohlavného štádia huby a následne v januári vytáranie peritécií (**Obrázok 1**) (ZÝKA et al., 2018).



Obrázok 1: Životný cyklus *G. piceae*. K napadnutiu dreviny dochádza v lete konídiami (k) a askospórami (a). Na púčikoch je možné pozorovať hnedé lezie počas jari. Mycélium pomerne rýchle napáda celý púčik kde sa v lete vytvorí nepohlavné štádium (NS), ktoré neskôr produkuje konídie. Patogén následne prežíva na púčiku do ďalšieho roku kedy vytvára pohlavné štádium (PS). (Zdroj: Zýka, 2018)

2.4 Diaľkový prieskum zeme (DPZ)

Diaľkový prieskum zeme (ďalej už iba DPZ) je vedou o získavaní informácií prostredníctvom metód, ktoré pomáhajú získavať poznatky o Zemi na diaľku pomocou snímacích zariadení umiestnených najčastejšie na lietadle alebo družici (LILLESAND et al., 2003). Jedným z dôležitých úkonov pri DPZ je správny výber senzorov. V súčasnej dobe neexistuje žiadny super senzor ktorý by zachytil všetky vlnové dĺžky a spektrá. Napríklad fotografické systémy dokážu zachytiť priestor vo veľkej kvalite s pomerne vysokými detailmi, no chýba im široký záber. V prípade nefotografických systémov zase môžu vznikať problémy v kvalite záberu alebo stabilite.

Pri výbere správneho systému na získanie snímok je vždy potreba zhodnotiť ciele práce, potrebnú kvalitu snímok pre výskum a ďalšie požiadavky, ktoré vyplývajú z daného výskumu.

Dôležitým aspektom pri získavaní snímok je taktiež druh platformy alebo vozidla, z ktorého sa snímky získavajú. Platformy môžu mať široký záber od rebríkov cez lietadlá, drony až po satelity. V posledných rokoch si našli tieto senzory veľké využitie pri dronoch, ktoré bývajú najčastejšie využívané a získavanie snímok pre DPZ (LILLESAND et al., 2015)

2.4.1. Družice

V súčasnej dobe je povrch Zeme monitorovaný veľkým množstvom družíc. Počiatkom toho snímkovania boli družice Landsat a Corona. V porovnaní s prvými družicami, kde snímky boli spätne posielané na Zem na kinofilmoch boli do súčasnej doby vyvinuté oveľa pokročilejšie technológie.

Družicové snímky sú získavané či už z vládnych tak aj súkromných družíc vo vesmíre. Môžu byť voľne dostupné ale taktiež v určitých prípadoch získané pod podmienkou zakúpenia licencie. Snímky môžu byť získané v rôznych merítkach, rozmeroch či vlnových dĺžkach. Pri družicových snímkach je veľmi podstatnou súčasťou ich rozlíšenie kde rozpoznávame štyri základné druhy rozlíšenia a to priestorové rozlíšenie, ktoré je možné jednoducho definovať ako veľkosť pixelu v družicovom snímku. Ďalej vieme o spektrálnom rozlíšení ktoré je definované ako vlnová dĺžka pásiem družicových snímok, stred pásiem a počet spektrálnych pásiem (SUROVÝ et al., 2019). Spektrálne pásma meriame prostredníctvom vlnových dĺžok v nanometroch (nm) a sú zaznamenávané v rozsahoch viditeľného žiarenia, infračerveného žiarenia a krátko vlnného žiarenia (CHANG, 2019). V prípade multispektrálnych snímok sa používa 3 – 10 pásiem o šírke 50 – 100 nm a v prípade hyperspektrálnej snímky môžu byť použité stovky pásiem so šírkou 2 – 10 nm. V zásade sa jedná o schopnosť rozlišovať odrazivosť objektov v priestore vlnových dĺžok. Časové rozlíšenie kde v podstate hovoríme o interval medzi dvoma po sebe idúcimi aktivizáciami a rádovo metrické rozlíšenie, ktoré sa všeobecne týka počtu bitov na pixel, ktoré sú využité na záznam obrazu.

Interpretácia družicových snímok často závisí od štyroch hlavných typov informácií a to od geometrickej informácie, radiometrickej informácie ako jas,

intenzita, tón. Spektrálnej informácie ako farba, odtieň a textúry ktorá je najdôležitejšou zložkou pri interpretácii (SUROVÝ et al., 2019).

2.4.2. Lietadlá

Dáta získané prostredníctvom lietadiel pre účely DPZ môžu byť veľmi vhodným nástrojom pri hodnotení atribútov lesa. Lesné podniky a celky, ktorých rozloha sa obvyčajne pohybuje okolo 10 000 ha môže jednoducho pokryť jedným letom.

Skenovanie sa obvyčajne vykonáva menšími lietadlami, ktoré na palube nesú zvyčajne viacej druhov senzorov. Jednx z typov lietadiel, ktoré sa používajú pre DPZ je typ Cessna 206 G, Cessna 208 B – Grand Caravan.

Pri snímaní zemského povrchu pomocou lietadiel je dôležité zohľadniť nasledujúce faktory a to sú:

- Letová výška
- Letová rýchlosť
- Prekryv letových línií
- Rýchlosť snímania snímkovacieho zariadenia

Letová výška, rýchlosť, prekryv línií a rýchlosť snímania závisia od typu lietadla a snímkovacieho zariadenia. Všeobecne však platí, že s vyššou výškou a vyššou rýchlosťou dochádza k zníženiu rozlíšenia snímky. Zväčšovaním prekryvu a použitím rýchlejšieho senzoru zase získame snímky s vyšším rozlíšením. V závislosti od druhu senzoru sa zorné uhly senzorov pohybujú v rozmedzí 40 -60° (SUROVÝ et al., 2019).

Z pohľadu využiteľnosti letecký skenerov bola v posledných rokoch venovaná pozornosť a následne porovnávanie leteckým laserovým skenerom (ALS – Aerial Laser Scanning) a v menšej miere digitálnej leteckej fotogrametrii (DAP – Digital Aerial Photogrametry). Ako jedna tak aj druhá metóda vedú k vytvoreniu 3D bodových mračien, však kvalita výsledku sa líši. V práci WALLACE et al., 2016 boli tieto dva druhy mračien porovnávané pri lietadlách ale aj pri dronoch. Z výsledkov bolo možné zistiť že fotogrametrické snímky poskytujú veľmi presné snímky povrchu vegetácie, no laserové snímanie je schopné zachytiť aj štruktúru porastu. Z týchto výsledkov zisťujeme že oba druhy skenerov ako ALS tak aj DAP nám sú schopné rovnocenne vyhodnotiť premenné z povrchu vegetácie (napr. výška,

priemer), ale čo sa týka premenných získaných zo štruktúry porastu (napr. kruhová základňa, biomasa, objem) ALS poskytuje presnejšie odhady (VASTARANTA et al., 2013).

Všeobecne môžeme systémy DPZ rozlišovať na aktívne a pasívne. Pasívne systémy zaznamenávajú prirodzené elektromagnetické žiarenie odrazené alebo vyžiarené. Ako príklad je možné uviesť fotoaparát. Aktívne systémy produkujú majú vlastný zdroj žiarenia. Systém vyšle impulz a meria spätný rozptyl odrazený do senzoru. Príkladmi aktívnych systémov sú napríklad radar, lidar a sonar (GIS GEOGRAPHY, 2021).

2.4.3. Bezpilotné lietadlá a drony

Zo všetkých uvedených druhov DPZ sa v posledných dvoch dekádach venuje veľká pozornosť bezpilotným lietadlám (UAV – Unmanned Aerial Vehicles), v zásade dronom a bezpilotným systémom (RPAS – Remotly Piloted Aerial System), ktoré umožňujú diaľkové ovládanie bezpilotných dronov. Tieto bezpilotné lietadlá a ďalšie bezpilotné systémy sa rýchlo stali často využívanou alternatívou oproti tradičným prostriedkom na DPZ. S príchodom a rýchlym vývojom týchto nových metód samozrejme prišlo aj široké spektrum využitia a aplikácií (COLOMINA et al., 2014; EVARAERTS, 2008).

Pri výbere vhodného bezpilotného lietadla alebo systému, musí spĺňať určité kritéria, kde jedným z hlavných je hmotnosť senzoru, na získavanie dát. Ďalej je potreba vedieť dĺžku letu, letové parametre. Po zhodnotení kritérií sa rozhoduje medzi dvoma hlavnými typmi UAV a to medzi multikoptérmi alebo krídlami. Multikoptéry majú jednu podstatnú výhodu pri skenovaní voči lietadlám a to možnosť zníženia rýchlosti na minimum, prípadné zastavenie na mieste čo je v niektorých prípadoch skenovania veľkou výhodou.

Pri skenovaní bezpilotnými lietadlami alebo multikotérmi je dôležitou súčasťou plánovanie a to hlavne z toho dôvodu aby sa zistilo či v danej oblasti nie sú zakázané, obmedzené prelety dronov prípadne či nejedná nebezpečný priestor.

Po získaní snímok je posledným a dôležitým krokom ich zálohovanie ale aj export z tzv. raw formátu. Je potreba ich exportovať do formátu JPEG, tak aby ich bolo možné ďalej spracovávať. Pri exporte je dôležité dbať na redukciu šumu, ktorá

by mohla mať za následok zhoršenie ich kvality a to by mohlo vyvolať problémy pri ďalšom spracovaní (SUROVÝ et al., 2019).

2.5 Deep learning

Deep learning (ďalej len DL) je jednou z metód strojového učenia založených na princípe umelých neurálnych sietí a ich učenia sa. DL využíva algoritmy s veľkým počtom vrstiev, ktoré reprezentujú dáta. Označenie DL vzniká z dôvodu vrstiev, ktoré sú zastúpené za sebou takým spôsobom že naväzujú svojimi výstupmi na vstupy nasledujúcej vrstvy. Toto učenie môže prebiehať troma rôznymi spôsobmi a to pod dozorom, čiastočným dozorom alebo bez dozoru (SCHMIDHUBER, 2015). Strojové učenie samo o sebe je veda o počítačových algoritmoch, ktoré sa zlepšujú prostredníctvom skúseností a pridávaním dát (MITCHELL, 1997).

DL má v súčasnosti veľké využitie pri strojovom učení bez dohľadu, pretože nevyznačené dáta ponúkajú väčšiu hojnosť pri vyhodnocovaní oproti tým vyznačeným (BENGIO et al., 2013). Od roku 2011 bolo možné pozorovať veľký rozvoj používania rozpoznávania snímok, hlavne rozpoznávanie tváre, kde môžeme pozorovať učenie sa pod dozorom za pomoci zadaných parametrov. Tento typ učenia sa preukázal byť veľmi presný v porovnaní s ľudskou zložkou pri rozpoznávaní tvárí (CIRESAN et al., 2012)

Umelé neurálne siete, ktorých je DL súčasťou sú založené na biologických procesoch v mozgu kde podstatným rozdielom medzi umelou neurálnou sieťou (ďalej len UNS) a živou je že UNS sú statické a symbolické zatiaľ čo tie skutočné sú dynamické a analógové (BENGIO et al., 2015).

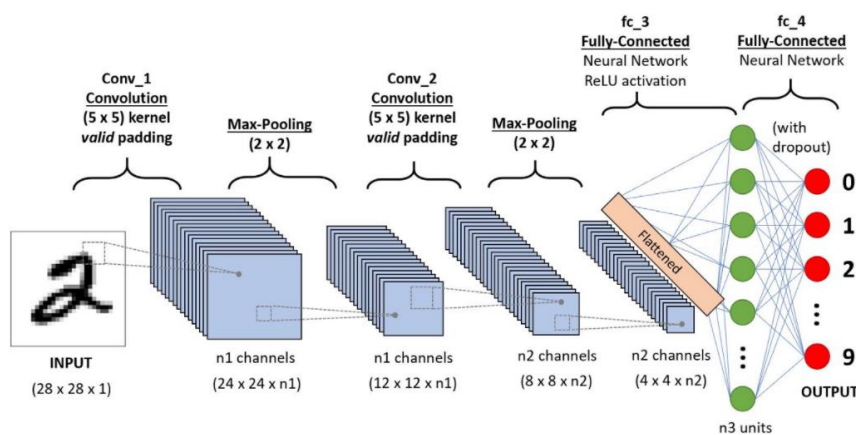
2.5.1. Konvolučné neurónové siete (CNN)

Konvolučné neurónové siete (ďalej iba CNN) sú z jedny veľmi dobre známych architektúr hlbokého učenia sa, ktoré boli založené na mechanizme vizuálneho vnímania živých organizmov (JIUXIANG et al., 2018). V súčasnosti tieto druhy sietí najčastejšie slúžia na rozpoznávanie snímok z družíc, dronov a iných zdrojov (VALUEVA et al., 2020), na hlasové rozpoznávanie alebo programovacie jazyky (JIUXIANG et al., 2018). Existujú rozličné druhy neurónových sietí, ale každá

neurónová sieť pozostáva z rovnakých komponentov ako sú neuróny, synapsie, funkcie a podobne. Pri CNN tak isto ako pri iných druhoch neurónových sietí je potreba zadať špecifické hyper parametre aby sme mohli získať výstupy na ktoré sa chceme zamerať (**Obrázok 2**). Preto sa v súčasnej dobe špecialisti snažia vytvoriť nový algoritmus, ktorý by mohol pomôcť získať potrebné detailné zábery bez zadávania detailných hyper – parametrov (ACHALA et al., 2021). Hyper parameter je parametrom, ktorého hodnota sa používa na samotné riadenie procesu. Obyčajne musia byť hyper parametre prednastavené pred samotným tréningom algoritmu (CLAESEN & MOOR, 2015).

Za posledných dvadsať rokov boli podniknuté rozsiahle kroky pre rozvoj neurónových sietí čo viedlo k úspešnejšiemu prekonávaní prekážok počas programového učenia. Príkladom subjektu ktorý sa venuje rozvoju a vytváraniu CNN je jedna z najznámejších firiem na trhu a to je Google. Práve táto firma využíva strojové učenie pre zákazníkov pri vyhľadávaní informácií v prvom okne po otvorení webového zdroja (SZEGEDY et al., 2015).

CNN rozvinuté na úrovni ako má Google môžu mať ale problém s tým ako hlboko je program rozvinutý čo môže viesť k odlišnostiam pri obsluhu akéhokoľvek nástroje popri jeho využívaní. Preto aj súčasnej dobe neustále prebieha zdokonaľovanie už vytvorených programov, aby bola možnosť vyvarovať sa chýbám v programovaní, ktorý by komplikovali využívanie umelých inteligencií (JIUXIANG et al., 2018).



A CNN sequence to classify handwritten digits

Obrázok 2: Spracovanie údajov pomocou CNN (Zdroj: <https://towardsdatascience.com/>. Saha, 2018)

2.5.2. TensorFlow

TensorFlow je systém strojového učenia ktoré funguje vo veľmi rozmanitom prostredí. Umožňuje vývojárom pracovať z rozsiahlym spektrom optimalizácií a tréningových algoritmov, ktoré následne napomáhajú tvorbe nových aplikácií so zameraním na tréning a rozvoj hlbokých neurónových sietí (Deep Neural Networks). TensorFlow využíva grafy toku údajov na znázornenie výpočtov, zisťovanie stavu výpočtu a následne taktiež na detekovanie operácií, ktoré spôsobujú zmeny, nepresnosti, v samotných výpočtoch.

TensorFlow je druhov generáciou programu DistBelief. Voči prvej generácii program TensorFlow umožňuje priebežné rozšírenie základného programu, čo napomáha používateľovi pri výpočtových a logistických aspektoch tréningu modelu (GOLDSBOROUGH, 2016).

Systém TensorFlow so zameraním na strojového učenie dokáže podporovať ako už existujúce aplikácie v ich tréningu a výpočtoch s rozsiahlym využitím veľkého množstva GPU, tak aj novo vznikajúce aplikácie (ABADI, 2016). zovšeobecňuje a zjednodušuje výstupy, čo má za úlohu napomáhať výskumníkom zamerať sa na širšie spektrum nápadov a prístupov s relatívnou ľahkosťou.

Oproti tradičným systémom toku údajov kde vrcholy grafov ukazujú informácie na nemeniteľných dátach, TensorFlow umožňuje hlásiť, prípadne aktualizovať dáta v premenlivom stave (CHEN et al., 2016).

Na vyjadrenie výsledkov strojového učenia využíva TensorFlow takzvané výpočtové grafy. Výpočtové grafy tiež ináč povedané v tomto prípade tok dát vytvára priame spojenia vrcholov a uzlov grafu ktoré opisujú vykonané operácie zatiaľ čo hrany vyjadrujú tok dát medzi jednotlivými operáciami (**Obrázok 3**).


Grafy tokov dát sa skladajú zo 4 hlavných komponentov ktorými sú operations (operácie), tensors (rozhrania – spojnice uzlov), variables (premenné) a sessions (finálneho hodnotenia).

V TensorFlow sú operácie reprezentované uzlami, ktoré vyjadrujú jednotlivé kombinácie a transformácie dát vyobrazených v grafoch (ABADI, 2016). Každá operácia môže mať neurčitý počet vstupov na základe čoho bude neskôr poskytovať výstupy programu. Operácia môže byť v programe vyjadrená rôznymi spôsobmi ako napríklad formou matematických rovníc, konštánt či už rôznych iných premenných.

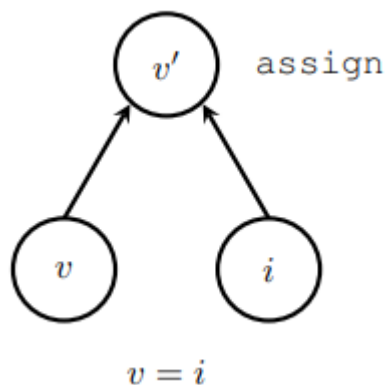
Rozhrania v grafe tokov dát spĺňajú úlohu prenosu informácií medzi jednotlivými operáciami. V jednoduchosti sa v zásade jedná o prenosy multi dimenzionálnych hodnôt medzi fixnými bodmi programu.

Premenné v programe možno opísať ako vytrvalé a meniteľné údaje pohybujúce sa v tensoroch. Každá premenná v analýze obrazu je charakteristická svojím tvarom a typom. Pri vytváraní uzlov premenných je potrebné charakterizovať hrany, ktoré budú graficky zobrazovať prepojenie uzlov ktorých výstupom bude vytvorenie požadovanej výslednej premennej ktorá vznikne kombináciou premenných v ich základnej podobe a premenných ktorá budú niesť mutačnú informáciu (**Obrázok 4**).

Sessions slúžia ako finálne hodnotenie výstupov programu TensorFlow. Sessions taktiež slúži ako vstupný bod, či už do celého programu tak aj do jeho častí v závislosti na požadovaných úpravách (GOLDSBOROUGH, 2016).



Obrázok 3: Príklad jednoduchého a komplexného výpočtového grafu pre TensorFlow. Graf nachádzajúci sa naľavo predstavuje jednoduchý výpočet pozostávajúci z dvoch vstupných údajov x a y . Z je v tomto prípade výstup operácie. Graf nachádzajúci sa napravo predstavuje komplexnejší prípad výpočtu logistickej premennej y , kde vektor x predstavujú hodnotený parameter, w opisuje váhu daného parametru a b opisuje variabilitu daného parametru ($x^T w$). Z je vyjadrením parametru $x^T w$ po započítaní jeho variability b . Prepočtom sigmy zo z získame reálny výsledok toho ako natrénovaný model hodnotí daný parameter x . (Zdroj: Goldsborough, 2016)




Obrázok 4: Kombináciou premennej v v nezmenenej podobe (i) a premennej ktorá nesie mutačnú informáciu (v) vznikne výsledná požadovaná premenná potrebná pre vytváraný algoritmus (Zdroj: Goldsborough, 2016)


2.5.3. MobilNet

MobilNet je efektívnou architektúrou hlbokého učenia, ktorá využíva hlboké delenie konvolúcií na vytvorenie zjednodušených konvolúcií. Toto zjednodušenie pomáha vytvoriť neurálne siete, ktoré vytvárajú jednoduchšie modely vhodné pre analýzy obrazu pomocou mobilných telefónov (HOWARD et al., 2017). Porozumieť tomuto procesu, najprv musíme pochopiť čo je to konvolúcia. Konvolúcia je matematický operácia dvoch funkcií, kde výsledkom je tretia funkcia ktorá vyjadruje ako tvar jednej funkcie ovplyvňuje tú druhú. Ešte jednoduchšie pre vysvetlenie môžeme povedať že dochádza k neustálym zmenám, rozličným usporiadanie a uloženiam, stavebných blokov obrázku, čo napomáha k lepšiemu výkonu a presnejším výsledkom pri učení (BAHRI et al., 2013).

Hlboká konvolúcia (**Obrázok 5**) je proces pri ktorom aplikujeme jeden konvolučný filter (kernel) na každý vstupný blok obrázku. Po rozložení na tieto základné bloky pomocou tréningový program v prípade MobileNetu rozloží bloky pomocou bodovej konvolúcie (**Obrázok 6**) na bloky o rozmeroch 1×1 pixelov, čo iba napomôže spresneniu výsledkov programu (KAISER et al., 2017).



Obrázok 5: Vizuálne vyobrazenie hlbkej konvolúcie. Podľa opisu z text môžeme vidieť ako hlboká konvolúcia rozdelí obrázok na bloky o menších rozmeroch a uloží ich za seba podľa usporiadanie farieb. Konvolúcia má svoj vzorec ($w \times h \times c$), ktorý pozostáva z troch prvkov. w označuje šírku, h výšku a v tomto prípade c označuje počet farieb. Tieto prvky taktiež v určitých prípadoch slúžia ko mapa obrázku tak aby sa vedelo z ktorej časti obrázku bloky pochádzajú (Zdroj: <https://paperswithcode.com/method/depthwise-convolution>. Wang, 2018)



Obrázok 6: Vizuálne vyobrazenie bodovej konvolúcie. (Zdroj: <https://paperswithcode.com/method/pointwise-convolution>. Wang, 2018)

2.5.4. Object based image analysis (OBIA)

Hlavnou úlohou OBIA pri diaľkovom prieskume zeme je poskytnúť vhodné a presné metódy pre analýzu obrazu vo vysokom rozlíšení. Pre dosiahnutie tohto výsledku OBIA využíva spektrálnu a priestorovú analýzu (SHAKYA et al., 2021).

Priestorová analýza v oblasti analýzy obrazu zohráva dôležitú rolu. Má za úlohu kategorizovanie jednotlivých pixelov na základe vzťahu so susednými pixelmi. Toto kategorizovanie prebieha na základe veľkosti, tvaru, smeru, textúry a mnohých ďalších podmienok (BISHOP, 2006). Takáto identifikácia obrazu je v princípe podobná identifikácii obrazu ľudským okom (LILLESAND et al., 2015).

3. Metodika

Oblasť z ktorej boli získané snímky stromov využitých v tomto výskume sa nachádza v blízkosti českej dediny Moldava umiestnenej v severovýchodnej časti Krušných horách (**Obrázok 7**). Nadmorská výška výskumnej oblasti sa pohybuje v rozmedzí od 832 do 867 metrov nad morom. Skupiny stromov určené pre získanie snímok boli rovnomerne rozmiestnené v oblasti približne o rozsahu 2,2 ha s takmer 460 jedincami druhu *P. pungens* (Engelm).



Obrázok 7 : Lokalita v ktorej sa vykonával výskum je vyznačená na mape zeleným bodom (Zdroj: mapy.cz)

Pre získavanie snímok boli použité dva druhy dronov a to dron DJI Mavic 2 (**Obrázok 8**) a DJI Phantom 4 Pro (**Obrázok 9**). Snímali sa tri stromy s rôznou úrovňou napadnutia *G. piceae*. Prostredníctvom dronov boli získané snímky v kvalite 5472 x 3648 pixelov.



Obrázok 8: DJI Mavic 2 (Zdroj: www.dji.com)




Obrázok 9: DJI Phantom 4 Pro (Zdroj: www.dji.com)

3.1. LabelImg

Na spracovanie fotiek bol využitý program LabelImg (TZUTALIN, 2015), v ktorom sme vyhodnocovali každý púčik jednotlivo podľa toho či bol napadnutý alebo zdravý. LabelImg je voľne dostupný zdroj s nástrojmi na grafické označovanie obrázkov. Snímky boli vyselektované podľa ostroty a jasnosti obrazu tak aby mohli poskytnúť čo najdetailnejšie záznamy, ktoré poskytnú čo najpresnejšie výstupy z programu TensorFlow. Klubnatka sa na snímkach vyznačila vo viacerých tvaroch a štádiach tak, aby bolo možné program naučiť čo najpresnejšie rozpoznávať napadnutie a selektovať zdravé púčiky od napadnutých (**Obrázok 10**). Po prvotnom spracovaní snímok bolo ale zistené že veľkosť snímok by komplikovala učenie nového algoritmu. Preto bol napísaný Ing. Karlem Matějkou, CSc., program ktorý mal za úlohu rozdeliť snímky na menšie úseky z pôvodných rozmerov 5472 x 3648 pixelov na 300 x 300 pixelov, čo umožní TensorFlow rýchlejšie spracovanie snímok ale taktiež poskytne väčšiu vzorku na testovanie funkčnosti programu (**Obrázok 11**).

Na nižšie umiestnených obrázkoch je možno vidieť že po prerobení snímok novým programom došlo k určitému zhoršeniu kvality. Preto musel byť každý jeden snímok znova skontrolovaný, prípadne prerobený, aby mohli byť napadnuté púčiky dobre viditeľné, čo je veľmi dôležité pre TensorFlow.

V prípade že by boli snímky nejasné, tak by to neskôr viedlo k zhoršeniu výsledkov, prípadne k zásadným problémom pri vývoji algoritmu, keďže zvýraznené objekty sami o sebe majú byť veľmi dobre rozoznateľné ľudským okom, aby bola zabezpečené plynulé bezproblémové testovanie. Zvýrazňovanie napadnutých a zdravých púčikov bolo zjednodušené vďaka rýchlym prístupom k jednotlivým úkonom v programe. Tieto úkony so skratkami boli súčasťou programu. V procese vytvárania nového algoritmu je najdlhšou a najpodstatnejšou prácou práve získanie základných údajov pre učenie čo zaisťuje program LabelImg.



Obrázok 10: LabelImg vyznačovanie údajov s rozdelením napadnutých a nenapadnutých púčikov

(Zdroj: Kristián Farárik, 2022)



Obrázok 11: LabelImg snímky po druhotnom spracovaní pre TensorFlow (Zdroj: Kristián Farárik, 2022)

3.2. Parametre algoritmu a prehľadová tabuľka počtov obrázkov a objektov

Pre výpočet bol použitý systém s parametrami uvedenými v **Tab. 1.** Najdôležitejšou časťou je grafická karta (GPU), v ktorej sa vyhodnocovali dáta. Grafická karta je pre tento typ práce d'aleko účinnejšia ako CPU, keďže sa jedná o paralelizáciu práce.

Parametre algoritmu boli stanovené nasledovne a to 80 % snímok bolo určených na tréning algoritmu a 20 % na testovanie (**Tab. 2.**). Počas tréningu boli snímky náhodne horizontálne prevracané s pravdepodobnosťou 50 % pre rozšírenie údajov.

Tento krok bol vykonaný pre väčšiu robustnosť údajov súboru. Ako bolo spomenuté v podkapitole 3.1, musela sa zmeniť mierka snímok na 300 x 300 pixelov. Pre potrebu učenia bol použitý model MobilNet (viz. podkapitola 2.5.3).

Tab. 1. Parametre použitého hardwaru

OS	Windows 10 x64
CPU	8x Advanced Micro Devices Vishera FX-8320 @3.5 GHz
RAM	16 GB DDR3 @1600 MHz CL 11
GPU	TU 102
GPU variant	TU 102-300A-K1-A1
GPU Architecture	Turing
GPU Transistor count	18.6 Bilion
GPU Tensor core count	544
GPU Memory size	11 GB
GPU Memory bus width	352 bit
GPU Memory bandwidth	616 GB/s
GPU Cuda FL	7.5
GPU FP 64 (double) performance	420.2 GFLOPS
Graphics card model name	Nvidia RTX 2080 Ti

Tab. 2. Prehľad počtov obrázkov a objektov

Obrázky a objekty	80 % (trénovanie)	20 % (testovanie)
Počet obrázkov	451	113
Počet klubnatiek	306	77
Počet zdravých púčikov	315	79

3.3. Štatistické vyhodnotenie

Pre našu prácu bolo použité strojové učenie pod dohľadom. Klasifikátory strojového učenia sú normálne tréované tak aby chyby čo najviac minimalizovali (YACOUBY & AXMAN, 2020). Pre účely našej práce bola využitý najčastejšie používaný spôsob vyhodnocovania presnosti klasifikátora pomocou klasifikačnej matice Precision, Recall a F1 score. Precision a Recall (presnosť a citlivosť) poskytujú informácie o správnosti klasifikátora (BUCKLAND & GEY, 1994). Ich kombinácia nám umožňuje objektívne vyhodnotiť výkon a presnosť modelov.

Pre vyhodnotenie týchto údajov sa využíva Confusion matrix (chybová matica) (**Obrázok 12**), pozostávajúca zo štyroch kategórií a to **TP** - True positive, **FP** – False positive, **TN** – True negative a **FN** – False negative (CHICCO et. JURMAN, 2020).

V jednoduchosti vysvetlené zisťujeme Precision pomerom TP a všetkých bodov klasifikovaných ako pozitívne (**Vzorec 1**). Recall sa zisťuje pomerom TP a sumou bodov TP a FN (**Vzorec 2**) (SIMON et al., 2019). F1 score (**Vzorec 3**) je Harmonickým priemerom Precision a Recall. V prípade väčšej nerovnováhy pomeru výsledkov Precision a Recall je vhodnejšie použiť práve toto skóre ako spôsob výpočtový výslednej hodnoty (CHINOR, 1992).

V prípade nášho učenia boli kategórie matice charakterizované nasledovne. **TP** (True positive) sme v našom prípade určili ako bod kedy model správne určil klubnatku alebo zdravý púčik. **FP** (False positive) boli body, ktoré model určil ako klubnatku alebo zdravý púčik, no v skutočnosti sa jednalo o ihličie, konár, prípadne prázdne miesto na snímke. **TN** (True negative) sme v našom prípade neurčovali keďže sme modelu zadali rozpoznať iba klubnatku a zdravý púčik. **FN** (False negative) sme určili porovnaním snímky z modelu a originálnej snímky, ale už iba pre klubnatku. Pokiaľ sa na originálnej snímke vyskytovalo viacej vyznačených objektov s klubnatkou, než model určil v testovacích snímkach, tak za každý nevyznačený objekt, ktorý model prehliadol bola danej snímke pridelená hodnota 1. Jediným rozdielom pri určovaní FN bolo Detscore. Detscore nebolo možné určiť, pretože sme porovnávali manuálne dve snímky voči sebe bez možnosti overenia modelom. Dôvodom, prečo bol zvolený daný postup na charakteristiku kategórie FN spôsobom aký bol zvolený, bolo testovanie prvej aplha verzie programu a zistenie jeho úspešnosti pri identifikácii patogénu. Charakteristika týchto

kategórií nebola prebrané z predpísaných alebo odporúčaných postup, no bola zvolená na základe subjektívneho rozhodnutia a konzultácie s vyučujúcim.

	Actual Positive	Actual Negative
Predicted Positive	tp	fp
Predicted Negative	fn	tn

Obrázok 12: Vzor chybovej matica pre binárnu klasifikáciu. Hlavná charakteristika bodov môže byť správne alebo nesprávne. Nesprávne určené body môžeme následne ďalej deliť na False positive alebo False negative (Zdroj: LIPTON et al., 2014)

$$p = tp / (tp + fp)$$

Vzorec 1: Výpočet hodnoty Precision (Zdroj: LIPTON et al., 2014)

$$r = tp / (tp + fn)$$

Vzorec 2: Výpočet hodnoty Recall (Zdroj: LIPTON et al., 2014)

$$F_1 \text{ score} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$$

Vzorec 3: Výpočet F1 score (Zdroj: CHICCO et JURMAN, 2020)

3.4. R software

R je software s otvoreným zdrojovým kódom pre štatistické výpočty a grafiku. Tento software je schopný pracovať vo viacerých druhoch platform ako Windows, Mac OS X alebo Linux. Pre jednoduchšie použitie a inštaláciou je R distribuované v binárnom formáte. S jeho vývojom, ktorý bol významne ovplyvnený S jazykom sa stalo R všeobecne využívaným jazykom pre štatistické výpočty v mnohých disciplínach akademickej obce a priemyselných odvetví.

Veľkou výhodou R je celosvetový úložný systém Comprehensive R Archive Network (CRAN) s doplnkovými balíkmi pridanými používateľmi, čo umožňuje v prípade riešenia problémov v softwari využiť kódy napísané užívateľmi, ktorý sa mohli stretnúť s rovnakými problémami. Aj napriek tomu že je R dizajnované na svoj vlastný kódovací jazyk, tak umožňuje interakciu aj s inými jazykmi ako napríklad C, C++, Java a podobne, pre výpočtové úlohy alebo pre využitie nástrojov. R ako aj ostatné programovacie jazyky je rozšírené o užívateľské integrované prostredie s funkciami pre prácu používateľa. Práve k takýmto úkonom slúži integrované vývojové prostredie ako RStudio (VERZANI, 2011).

Pre výpočet výsledkov Precision, Recall a F1 score bol použitý software R verzia 4.0.2. (R CORE TEAM, 2020), s ručným výpočtom chybovej matice obsahujúci súčet TP, FP, TN a FN.

3. 5. Výstupy XML súborov

Každá snímka kde boli modelom nájdené zdravé púčiky alebo púčiky napadnuté klubnatkou vyprodukovala XML súbory, ktorého výstupy boli neskôr použité pri vyhodnocovaní výsledkov. Výstupné XML súbory ktoré sme získali boli určené na základe tresholdu. Treshold bola predom stanovená minimálna presnosť určenia bodu pre model. V našom prípade 30% alebo 50%. Pokiaľ sa na snímke vyskytoval nejaký púčik, či už zdravý alebo napadnutý klubnatkou a jeho presnosť určenia bola buď pod 30% alebo 50%, tak bola modelom automaticky vyradená. Každý XML súbor nám poskytol informáciu o súradnicovom umiestnení nájdených objektov na snímke (*xmin*, *ymin*, *xmax*, *ymax*), informáciu o názve snímky (<filename>), či sa jednalo o zdravý púčik alebo klubnatku (<name>) a presnosť určenia (<detScore>) (**Obrázok 13**).

S väčším počtom nájdených objektov sa zvyšoval počet výstupov v XML súbore. Ako už bolo vyššie spomenuté, každý objekt mal svoje súradnice, ktoré neskôr pomohli s presným vylíšením objektov na obrázkoch. Toto bolo dôležité pre zápis do excel súboru a to z toho dôvodu, aby nedošlo k zámene pri manuálnom hodnotení presnosti modelu.

```
<?xml version="1.0"?>
- <annotation>
  <folder>KLOUBNATKA</folder>
  <filename>2-DJI_0005_1_1.jpg</filename>
  - <size>
    <width>300</width>
    <height>300</height>
    <depth>3</depth>
  </size>
  <segmented>0</segmented>
  - <object>
    <name>kloubnatka</name>
    <detscore>0.3977</detscore>
    - <bndbox>
      <xmin>108</xmin>
      <ymin>187</ymin>
      <xmax>140</xmax>
      <ymax>217</ymax>
    </bndbox>
  </object>
</annotation>
```

Obrázok 13: XML výstup modelu

4.2. Evaluácia XML súborov podľa kategórií chybovej matice

XML výstupy boli zapisované do excel tabuliek. Údaje ktoré boli použité z výstupov XML boli name, detscore a name. Pre zjednodušenie údajov pri zápise sme názov snímky pomenovali ako Name a púčky ako Pupen.


Výstupy XML súborov boli rozdelené do dvoch tabuliek podľa informácie Treshold (Obrázok 14). Z dôvodu rozsiahleho množstva údajov v databáze , ktoré by nebolo možné vložiť do tejto diplomovej práce bola vo výsledkoch zvolená interpretácia pomocou grafov, ktoré jasne popisujú pomer zastúpení jednotlivých kategórií chybovej matice.

Threshold	Name	Detscore	Pupen	TP	FP	TN	FN
30	2-DJI_0005_1_1.jpg	0,3977	kloubnatka	0	1	0	0
30	2-DJI_0005_1_1.jpg		kloubnatka	0	0	0	1
30	2-DJI_0005_2_1.jpg	0,9534	zdravy	1	0	0	0
30	2-DJI_0005_2_1.jpg	0,5193	zdravy	0	1	0	0
30	2-DJI_0005_2_1.jpg	0,3463	zdravy	1	0	0	0
30	2-DJI_0005_2_1.jpg	0,3235	zdravy	0	1	0	0
30	2-DJI_0005_6_1.jpg	0,3177	kloubnatka	0	1	0	0
30	2-DJI_0005_8_1.jpg	0,3084	kloubnatka	0	1	0	0
30	2-DJI_0005_8_1.jpg		kloubnatka	0	0	0	1
30	2-DJI_0007_2_1.jpg	0,9036	kloubnatka	1	0	0	0
30	2-DJI_0015_3_1.jpg	0,3482	kloubnatka	1	0	0	0
30	2-DJI_0015_4_1.jpg	0,9479	zdravy	0	1	0	0
30	2-DJI_0015_8_1.jpg	0,3855	kloubnatka	1	0	0	0

Obrázok 14: Vzor výstupov tabuliek s určením kategórií chybovej matice

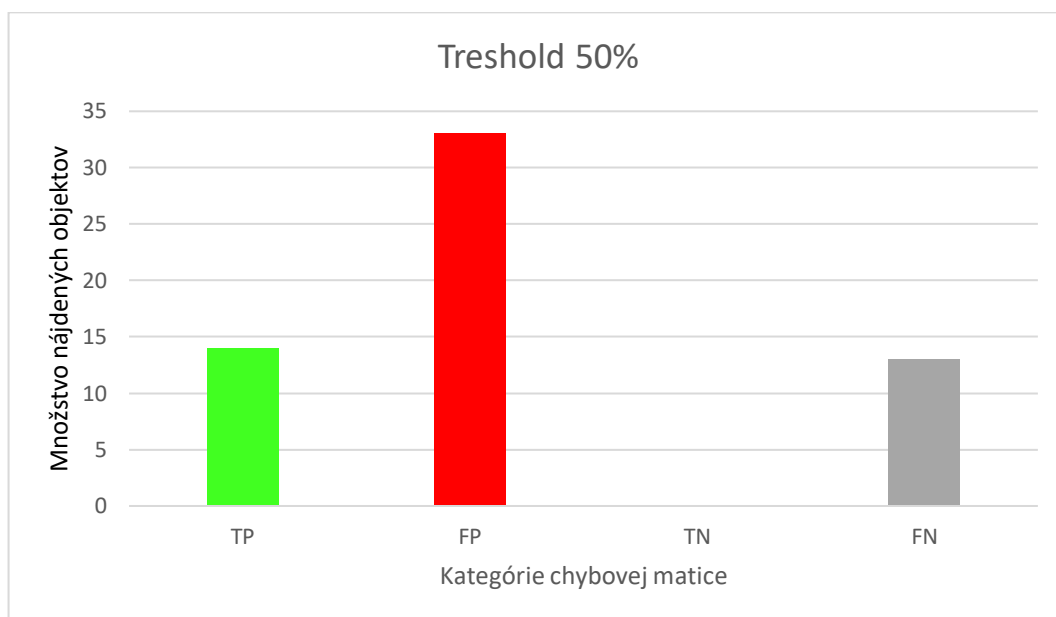
4. Výsledky

Z nižšie uvedených grafov, ktoré predstavujú prevod údajov z tabuliek spomínaných v podkapitole 4.2. je možné pozorovať výrazný rozdiel v množstve určenia TP. V prípade Tresholdu 30 % (**Obrázok 15**) algoritmus úspešne rozpoznal (TP) 54 púčikov . Z toho bolo správne určených 35 objektov s klubnatkou a 19 objektov so zdravým púčikom. Kategória FP v prípade Tresholdu 30% bola o niečo nižšia oproti TP. Model nesprávne určil 33 objektov, ktoré boli označené vo výstupoch XML ako klubnatka alebo zdravý, no v skutočnosti sa jednalo len o zámenu s ihličím alebo konármi. Z tohto počtu bolo nesprávne určených 25 objektov ako kloubnatka a 8 ako zdravý. Podľa kategórie FN model neoznačil 26 púčikov napadnutých klubnatkou. Celkový počet identifikovaných objektov v kombinácii s FN pre Treshold 30 % bol 113.



Obrázok 15: Graf s minimálnou presnosťou Tresholdu 30%

Podľa nastavenia minimálnej presnosti Tresholdu 50% (**Obrázok 16**) bolo úspešne rozpoznávaných (TP) 14 objektov. Z toho sa jednalo o 10 správne rozpoznávaných objektov s klubnatkou a 4 objekty so zdravými púčikmi. Nesprávne určeným (FP) bolo 33 objektov. V tomto prípade sa jednalo o 19 objektov s klubnatkou a 14 objektov označených ako zdravý. V prípade Tresholdu 50% nebol algoritmus schopný rozpoznat' 13 púčikov napadnutých klubnatkou. Celkový počet indetifikovaných objektov v kombinácii s FN pre Treshold 50% bol 60.



Obrázok 16: Graf s minimálnou presnosťou Thresholdu 50%

4.3. Výstupy softwaru R

Pre výpočet výsledkov Precision, Recall a F1 score bol použitý software R verzia 4.0.2. (R CORE TEAM, 2020), s ručným výpočtom chybovej matice obsahujúci súčet TP, FP, TN a FN. Nižšie zistené údaje nám uvádzajú aký druh kódu bol použitý pre výpočet Precision, Recall a F1 score. Výsledky ktoré sme získali po výpočte pomocou týchto kódov a ich grafické prevedenie s porovnaním úspešnosti v závislosti od Thresholdu.

4.3.1. Výsledky výpočtu hodnoty Precision

V kóde uvedenom na **Obrázku 17** môžeme v prvom riadku vidieť aký druh vzorca bol použitý pre výpočet. TP ako aj FP obsahovalo celkový počet klubnatiek alebo zdravých púčikov pre danú kategóriu rozdelených pomocou Thresholdu. Pokiaľ sa napríklad teda jednalo o výpočet Precision pre kloubnatka 30, do vzorca bol vložený iba súčet úspešne identifikovaných klubnatiek ako TP a súčet neúspešne identifikovaných klubnatiek ako FP. Obdobný postup bol zvolený aj pre zdravé púčiky.

```

# Precision: tp/(tp+fp):
>
#Precision kloubnatka 30
pk30<-CFM[1,3]/sum(CFM[1,3:4])
>
#Precision zdravý 30
pz30<-CFM[2,3]/sum(CFM[2,3:4])
>
#Precision kloubnatka 50
pk50<-CFM[3,3]/sum(CFM[3,3:4])
>
#Precision zdravý 50
pz50<-CFM[4,3]/sum(CFM[4,3:4])

```


Obrázok 17: Kódovanie použité pre výpočet Precision

Z hodnôt úspešnosti určenia Precision je možné zistiť že v oboch prípadoch ako už pri kloubnatka 30 (0,58 tak aj zdravý 30 (0,70) bolo dosiahnuté väčšej úspešnosti pri určovaní napadnutých a zdravých púčikov vzhľadom k prahu 50. V prípade určenia kloubnatky podľa Tresholdom 50 % bola úspešnosť o niečo nižšia (0,3448276), no v prípade zdravých púčikov môžeme pozorovať výrazný rozdiel pri určovaní (0,222222) (**Tab. 3.**).

Tab. 3. Hodnoty zistené po výpočte Precision

Precision			
kloubnatka 30	kloubnatka 50	zdravy 30	zdravy 50
0,58	0,34	0,70	0,22

Po zistení hodnoty Precision, boli výsledky prevedené do grafického zobrazenia (**Obrázok 18**), kde môžeme lepšie pozorovať rozdiely ktoré vznikali porovnávaním výsledkov s Tresholdom 30 % a 50 %. Ako sa už spomínalo v predošlom odseku je možné pozorovať menší rozdiel neúspešnosti pri určovaní kloubnatky pri Tresholde 50 %, no výrazný rozdiel pri určovaní zdravých púčikov pri podmienke rovnakého Tresholdu.



Obrázok 18: Grafické prevedenie výsledkov Precision

4.3.2. Výsledky výpočtu hodnoty Recall

V kóde uvedenom na **Obrázku 19** môžeme v prvom riadku vidieť aký druh vzorca bol použitý pre výpočet. TP obsahovalo celkový počet klubnatiek alebo zdravých púčikov pre danú kategóriu rozdelených pomocou Tresholdu, no FN ako bolo spomenuté v metodike obsahovalo iba súčet klubnatiek , ktoré boli hlavný zameraním tejto práce.

```
# Recall: tp/(tp + fn):
>
#Recall kloubnatka 30
rk30<-CFM[1,3]/sum(CFM[1,3],CFM[1,6])
>
#Recall zdravý 30
rz30<-CFM[2,3]/sum(CFM[2,3],CFM[2,6])
>
#Recall kloubnatka 50
rk50<-CFM[3,3]/sum(CFM[3,3],CFM[3,6])
>
#Recall zdravý 50
rz50<-CFM[4,3]/sum(CFM[4,3],CFM[4,6])
```


Obrázok 19: Kódovanie použité pre výpočet Recall

Zo získaných údajov citlivosti algoritmu vyjadrenej ako Recall pre nás mali hlavný význam iba hodnoty pre klubnatka 30 a klubnatka 50. Z výsledkov môžeme zistiť vyššiu citlivosť algoritmu pri 30 % Tresholdu pre klubnatku (0,57) ale o niečo nižšiu pri Tresholde 50 % (**Tab. 4.**). Výsledky pre hodnotenie citlivosti identifikácie zdravých púčikov pre nás v tomto bode nezohrávali veľkú úlohu a to z dôvodu, ktorý bol spomenutý v odseku kódovania.

Tab. 4. Hodnoty zistené po výpočte Recall

Recall			
kloubnatka 30	kloubnatka 50	zdravy 30	zdravy 50
0,57	0,43	1	1

Zo zistených výsledkov ako pri Precision tak aj pri Recall boli hodnoty prevedené do grafického prevedenia (**Obrázok 20**). Z výsledkov môžeme pozorovať miernejší rozdiel výsledkov pre Treshold 30 % (0,5737705) a Treshold 50 % (0,434726) v citlivosti určovania objektov algoritmom. Výsledky hodnôt pre zdravé púčiky v tomto bode nie sú brané do úvahy a to z dôvodu chýbajúcej hodnoty FN.



Obrázok 20: Grafické prevedenie výsledkov Recall

4.3.3. Výsledky výpočtu hodnoty F1 score

V prvom riadku kódu **Obrázku 21** je popísaný kód využitý pre výpočet hodnoty F1 score. Do tohto výpočtu boli vložené iba výsledky zistené z predošlých výpočtov Precision a Recall.

```
# F-Score: 2 * precision * recall /(precision + recall):  
>  
#F-Score kloubnatka 30  
2*pk30*rk30/(pk30+rk30)  
>  
#F-Score zdravý 30  
2*pz30*rz30/(pz30+rz30)  
>  
#F-Score kloubnatka 50  
2*pk50*rk50/(pk50+rk50)  
>  
#F-Score zdravý 50  
2*pz50*rz50/(pz50+rz50)
```

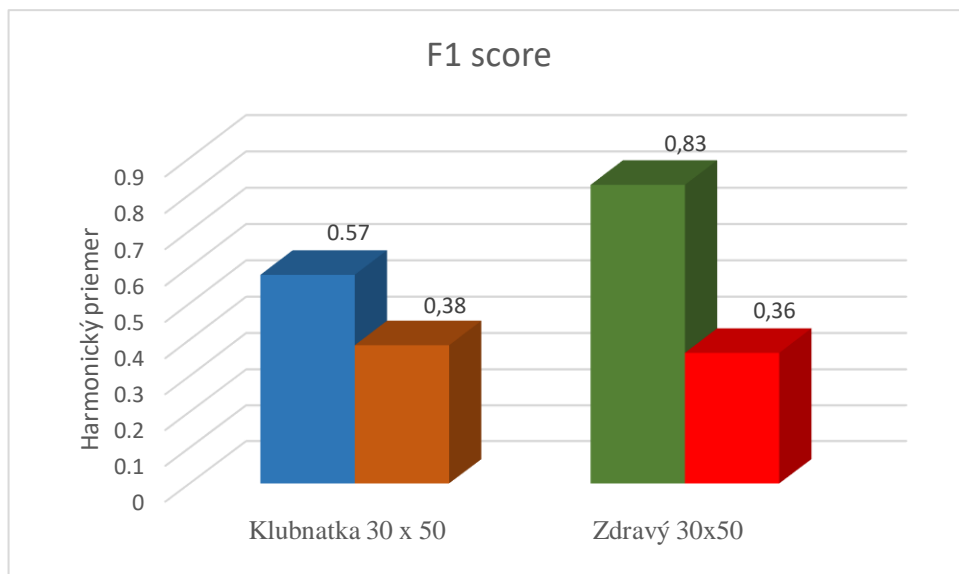
Obrázok 21: Kódovanie použité pre výpočet F1 score

Zo zistených údajov môžeme pozorovať takmer 58 % úspešnosť určovania klubnatky algoritmom pri zvolenom Tresholde 30 %. Pri voľbe Tresholdu 50% môžeme vidieť výrazný pokles úspešnosti určovania klubnatky algoritmom takmer o 20% (**Tab. 5.**). Výsledné hodnoty pre zdravé púčky mali menší význam a to z dôvodu výslednej hodnoty Recall, ktorá bola výrazne ovplyvnená kategóriou FN, ktorá jej v našom vyhodnocovaní nebola priradená.

Tab. 5. Hodnoty zistené po výpočte F1 score

F1 score			
kloubnatka 30	kloubnatka 50	zdravy 30	zdravy 50
0,57	0,38	0,83	0,36

V grafickom prevedení tabuľky 3 (**Obrázok 22**), možno pozorovať vyššie spomínaný výrazný rozdiel celkovej úspešnosti určovania objektov algoritmom z hodnôt 0,5785124 pre Treshold 30 % a 0,3846154 pre Treshold 50 %.



Obrázok 22: Grafické prevedenie výsledkov F1 score

5. Diskusia

Z výsledkov získaných výpočtom F1 score sme zistili, že celková úspešnosť identifikácie *G. piceae* na napadnutých jedincoch druhu *P. pungens* je vyššia pri Tresholde 30 % (0,5785124) ako pri Tresholde 50 % (0,3846154). S touto informáciou by bolo pre nás samozrejme vhodnejšie použiť nižšiu hranicu Tresholdu, čo by nám poskytlo vyššie výsledky celkovej úspešnosti pri identifikácii klubnatky. Táto informácia je však ovplyvnená nepomerom získaných identifikovaných objektov algoritmom.

Z informácií poskytnutých v prvej časti výsledkov bol zistený tento nepomer získaných údajov, kde sa uvádza že celkový počet identifikovaných objektov v prípade Tresholdu 30 % bol 113 a celkový počet identifikovaných objektov pre Treshold 50 % bol 60. V oboch prípadoch boli k počtom TP a FP pripočítané aj počty FN. Z týchto údajov podiel, pri Tresholde 30%, správne určených (TP) klubnatiek z celkového počtu objektov TP (54) bol 64,8 % (35 správne určených). Podiel ku množstvu nesprávne identifikovaných (FP) objektov (33) bol 75,8 % (25 nesprávne určených). Podiel k množstvu správne identifikovaných (TP) (14) pri Tresholde 50 % bol 71,4 % (10 správne určených) a podiel k množstvu nesprávne určených objektov (FP) (33) bol 57,6 %. Množstvo neidentifikovaných objektov (FN) pre Treshold 30 % bol 26 a množstvo neidentifikovaných objektov pre Treshold 50 % bol 13.

Z tohto uhla pohľadu môžeme povedať, že aj napriek väčšej úspešnosti identifikácie pri Tresholde 30 % zistenej pomocou F1 score nám algoritmus s vyššou hranicou Tresholdu poskytuje presnejšie údaje.

Na základe tohto zistenia je pre nás dôležité sa rozhodnúť či budeme uprednostňovať väčšie množstvo snímok s obsiahlejším množstvom identifikovaných objektov s väčšou chybovosťou alebo menšie množstvo snímok, ktoré nám síce poskytne menej výsledných objektov, no s menšou chybovosťou identifikácie patogénu.

Ďalším pomerne významným činiteľom, ktorý ovplyvňoval učenie algoritmu bola kvalita fotiek použitá pre tréovanie a testovanie modelu, ktorá zohráva dôležitú rolu pri identifikácii. Rozrezaním fotiek z dôvodu veľkých rozmerov, ktoré by robili problém pri tréovaní algoritmu došlo k zhoršeniu kvality snímok, čo malo výrazný vplyv na úspešnú identifikáciu klubnatky a zdravých púčikov. LILLESAND

et al., 2015 uvádza, že identifikácia objektov na snímkach pomocou umelej inteligencie je veľmi podobná identifikácii objektov pomocou ľudského oka. Táto skutočnosť nám hovorí, že s rastúcou kvalitou snímok nám taktiež narastá kvalita získaných údajov po vyhodnotení.

Napriek skutočnosti že s narastajúcou kvalitou snímok získame lepšie výsledky pri identifikácii patogénov, stále tu ostáva otázka premenných ako napríklad štádia patogénov ich rôzne varianty a podobne, ktoré majú podstatný vplyv na učenie umelej inteligencie.

Okrem prístupu, ktorý sme zvolili pri charakteristike kategórií chybovej matice bol taktiež prehodnocovaný ďalší prístup kde by TP bolo určené ako klubnatka, FP ako zámena so zdravým, TN ako zdravý a FN ako zámena s klubnatkou, no po manuálnej kontrole a porovnaní všetkých snímok sme zistili, že algoritmus takúto chybu nerobil a z tohto dôvodu bol zvolený práve náš prístup.

Pri písaní diplomovej práce a získavaní zdrojov sme zistili, že v danej oblasti učenia umelej inteligencie pomocou identifikácie a analýzy obrazu pre oblasť lesníctva bolo zrealizovaných len veľmi malý počet výskumov. Vo výskume od autorov SARKER et al., 2020 z Bangladéšu, ktorá sa venovala identifikácii listovej škvrnitosti na viniči druhu *Piper betle* L. bolo zistené že s väčšou kvalitou snímok narastá presnosť určenia patogénov, čo potvrdzuje aj 90% úspešnosť identifikácie ich algoritmu. Táto skutočnosť nám potvrdzuje našu hypotézu, avšak v porovnaní s výskumom pre identifikáciu lesného požiaru v poraste uskutočnením autormi ZHANG et al., 2016 sme zistili že podiel na vysokej úspešnosti výsledkov tréningu a testovania algoritmu má aj druh modelu, ktorý je používaný. Prípade tohto výskumu boli vypočítané výsledky presnosti tréningu 93,1% a testovania 88,6% na pomerne malom množstve snímok a to 178 snímok pre tréning a 59 pre testovanie. Pre účely tohto tréningu bol použitý pred tréningom model AlexNet, ktorého učenie prebiehalo už na tisícoch snímkach, čo výrazne zvýšilo úspešnosť správneho určovania identifikačných blokov obrázku. Tento výsledok bol taktiež podporený tým, že farba ohňa je jednoduchšie rozpoznateľnejšia od šumu pozadia snímky naproti klubnatke ktorá svojou tmavou farbou a zhoršenou kvalitou obrazu môže splývať s pozadím snímky, čo výrazne zťažuje jej identifikáciu. Pre budúci výskum sa vo výskume odporúčala jemnejšia zrnitosť obrazu, čo znova potvrdzuje našu hypotézu vyššej kvality obrazu.

6. Záver

Na základe zistených údajov s výpočtu F1 score sme zistili že s klesajúcim Thresholdom nám narastá úspešnosť identifikácie patogénu na drevine. S neskorším porovnaním údajov v diskusii sme však zistili že aj napriek viac než 50 % úspešnosti algoritmu pri rozoznávaní napadnutých púčikov od zdravých nebolo do úvahy brané množstvo získaných snímok po testovaní algoritmu. Táto skutočnosť má vplyv na samotné výsledky. Z tohto dôvodu sa okrem lepšej kvality snímok, väčšieho množstva záznamov pre trénovanie a možnej zmeny charakteristiky kategórií chybovej matice odporúča aj zohľadnenie viacerých premenných ako napríklad práve nepomer množstva získaných identifikovaných záznamov po testovaní pre každý Threshold osobitne. Pre budúci výskum by bolo vhodné zvážiť aj iné druhy modelov učenia s možnosťou porovnať výkonnosti modelov medzi sebou.

Odporúča sa ďalší výskum so zameraním sa aj na iné druhy patogénov. Táto inovácia v oblasti lesníctva môže priniesť veľké výhody z hľadiska spôsobu získavania informácií o zdravotnom stave porastov.

7. Zoznam použitej literatúry

ABADI, M. (2016). TensorFlow: A system for large-scale machine learning. Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI '16), Savannah, GA. USA. s. 1–21. ISBN 978-1-931971-33-1.

ACHALA S.; MANTOSH B.; MAHESH P. Parametric study of convolutional neural network based remote sensing image classification, International Journal of Remote Sensing, 2663-2685, India. [s. n.], 2021 [cit. 2021-05-30]. Dostupné z WWW: <https://apps.webofknowledge.com/full_record.do?product=WOS&search_mode=GeneralSearch&qid=1&SID=F2U86BOEj2PF6x3sk9o&page=1&doc=1>.

BAHRI, M.; AHINO, R.; VAILLANCOURT, R. (2013). Convolution Theorems for Quaternion Fourier Transform: Properties and Applications.

BALCAR, V.; KULA, E.; LOMSKÝ, B.; MAUER, O.; ŠRÁMEK, V. (2008). Porosty náhradních dřevin (PND) a jejich ohrožení biotickými a abiotickými faktory. In: Slodičák, M.; Balcar, V.; Novák, J.; Šrámek, V. (ed) Lesnické hospodaření v Krušných horách. LČR a VÚLHM, Hradec Králové & Strnady. s. 179 – 200.

BALCAR, V.; ŠRÁMEK, V.; BURIÁNKE, V.; HAVRÁNEK, F.; JURÁSEK, A.; LIŠKA, J.; NOVÁK, J.; SLODIČÁK, M. et al. (2015). Aktualizace studie – lesnické hospodaření v Krušných horách. Výskum ústav lesního hospodářství a myslivosti . Kapitola 3 - Ohrožení porostů náhradních dřevin Krušných hor biotickými škůdci – výsledky terénních štréní v roce 2015. Vol. 1. s. 35 - 52.

BALLARD, T.; DOSSKY, M. (1985). Needle water potential and soil-to-foilage flow resistance during soil dying a comparsion of Douglas – fir, western hemlock and mountain hemlock. Canadian Journal of Forest Research. s. 185 – 188.

BENGIO, Y.; COURVILLE, A.; VINCENT, P. Representation Learning: A Review and New Perspectives. IEEE Transactions on Pattern Analysis and Machine Intelligence. 35 (8) s. 1798–1828. [s. n.], 2013, [cit. 2021-12-29]. Dostupné z WWW: <<https://ieeexplore.ieee.org/document/6472238>>.

BENGIO, Y.; LEE, D.H.; BORNSCHEIN, J.; MESNARD, T.; LIN, Z. Towards Biologically Plausible Deep Learning. [s. n.], 2015 [cit. 2021-12-28] Dostupné z WWW: <<https://arxiv.org/abs/1502.04156>>.

BISHOP, M. CH. (2006). Pattern recognition and Machine learning. Cambridge: Cambridge. s. 21 – 26 . ISBN – 10: 0-387-31073- 8.

- BRIER, G. W. (1950).** Verification of forecasts expressed in terms of probability. *Monthly Weather Review*, 78. s. 1 – 3.
- BUCKLAND, M.; GEY, F. (1994).** The relationship between recall and precision. *J Am Soc Inform Sci*. Vol. 1. s. 9 – 12.
- CIRESAN, D.; MEIER, U.; MASCI, J.; SCHMIDHUBER, J.** Multi-column deep neural network for traffic sign classification. *Neural Networks. Selected Papers from IJCNN 2011*. 32. [s. n.], 2012 [cit. 2021-12-29]. Dostupné z WWW: <<https://www.sciencedirect.com/science/article/pii/S0893608012000524>>.
- CLAESEN, M.; MOOR, B.D. (2015).** Hyperparameter Search in Machine learning. s. 1 – 3.
- COLOMINA, I.; MOLINA, P. (2014).** Unmanned Aerial Systems for Photogrammetry and Remote Sensing: A Review *ISPRS Journal of Photogrammetry and Remote Sensing* 92. s. 79 – 97.
- ČERNÝ, K. (2016).** Nepůvodní invazní patogeny dřevin – výzva nebo předem ztracený boj? *Živa* 2016, s. 286–291.
- ČERNÝ, K.; PEŠKOVÁ, V.; SOUKUP, F.; HAVRDOVÁ, L.; STRNADOVÁ, L.; ZAHRADNÍK, D.; HRABĚTOVÁ, M. (2016).** *Gemmamyces* bud light of *Picea pungens*: a sudden disease outbreak in central Europe. *Plant Pathology*. Vol. 65. s. 1267 – 1278.
- DASSOT, M.; CONSTANT, T.; FOURNIER, M. (2011).** The use of terrestrial LiDAR technology in forest science: application fields, benefits and challenges. *Ann. For.Sci.* 68. s. 959–974.
- DEMEK, J. et al. (1965).** *Geomorfologie českých zemí*. 1. vyd. Praha: NČSAV. 335 s.
- DINGA, R.; BRENDA, W. J. H.; PENNIX; VELTMAN, D. J.; SCHMAAL, L.; MARQUAND, A. F. (2019).** Beyond accuracy: Measures for assessing machine learning models, pitfalls and guidelines.
- EVARAERTS, J. (2008).** The Use of Unmanned Aerial Vehicles (UAVs) for Remote Sensing and Mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXX-VII (Part B1)*. s. 1187 – 92.
- GHUFFAR, S.; SZÉKELY, B.; RONCAT, A.; PFEIFER, N. (2013).** Landslide displacement monitoring using 3D range flow on airborne and terrestrial LiDAR data. *Remote Sens.* 5. s. 2720–2745.
- GIS GEOGRAPHY. (2021).** Passive vs Active Sensors in Remote Sensing.

- GOLDSBOROUGH, P. (2016).** A tour of TensorFlow. Proseminar Data Mining. Munchen.
- HAWKSWORTH, F.; WIENS, D. (1972).** Biology and classification of the dwarf mistletoes (Arceuthobium). U. S. Department of Agriculture. Agriculture Handbook 401. Washington. DC. s. 234.
- HOPKINSON, C.; CHASMER, L.; YOUNG - POW, C.; TREITZ, P. (2004).** Assessing forest metrics with a ground-based scanning lidar. *Canad. J. For. Res.* 34. s. 573–583.
- HOWARD, A.G.; THU, M.; CHEN, B.; KALENICHENKO, D.; WANG, W.; WEYAND, T.; ADREETTO, M.; ADAM, H. (2017).** Mobilenets: efficient convolutional neural networks for mobile vision applications. 1. vyd. Google.
- CHANG, K.T. (2019).** Introduction to geographic information systems. 9 th ed. LSC Communications. 419 s. ISBN 978-1-259-92964-9.
- CHEN, J.; MONGA, R.; BENGIO, S.; JOZEFOWITZ, R.** Revisiting distributed synchronous SGD. In Proceedings of ICLR Workshop Track. [s. n.], 2016 [cit. 2022-03-21]. Dostupné z WWW: <<https://arxiv.org/abs/1604.00981>>.
- CHICCO, D.; JURMAN, G.** The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics* 21, Vol. 6. [s. n.], 2020 [cit. 2022-04-27]. Dostupné z WWW: <<https://doi.org/10.1186/s12864-019-6413-7>>.
- CHINOR, N. (1992).** MUC – 4 evaluation metrics. In: Proceeding of MUC – 4 – the 4th Conference on Message Understanding. McLean: Association for Computational Linguistics. s. 9 – 22.
- JAKLITSCH, W.M.; VOGLMAYR, H. (2017).** Three former taxa of Cucurbitaria and considerations on Petrakia in the Melanommataceae. *Sydowia*. Vol. 69. s. 80.
- JIUXIANG, G.; ZHENHUA, W.; KUEN, J.; LIANYANG, M. et al. (2018).** Recent advances in convolutional neural networks. *Pattern Recognition*. Volume (77). s. 354 – 377.
- KAASALAINEN, S.; KROOKS, A.; LISKI, J.; RAUMONEN, P.; KAARTINEN, H.; KAASALAINEN, M. (2014).** Change detection of tree biomass with terrestrial laser scanning and quantitative structure modelling. *Remote Sens.* 6. s. 3906–3922.
- KAISE, L.; GOMEZ, A. D.; CHOLLET, F. (2017).** Depthwise separable convolutions for Neural Machine Translation. Volume 2.

- KUBELKA, L.; KARÁSEK, A.; RYBÁŘ, V.; BADALÍK, V.; SLODIČÁK, M. (1992).** Obnova v imisemi poskozované oblasti severovýchodního Krušnohoří. Praha. MZe ČR. s. 133.
- LILLESAND, M.; KIEFER, R.; CHIPMAN, J. (2003).** Remote sensing and image interpretation. 5 th ed. USA. 736 s. ISBN 0-471-15227-7.
- LILLESAND, M.; KIEFER, R.; CHIPMAN, J. (2015).** Remote sensing and image interpretation. Chapter 7 – Digital Image Analysis. 7 th. ed. USA. 736 s. ISBN 978-1-118-34328-9.
- LOCHMAN, V.; ŠRÁMEK, V.; FADRHOŇSOVÁ, V.; LACHMANOVÁ, Z. (2008).** Změny zásoby sledovaných prvků v lesních půdách na plochách Moldava v Krušných horách. Zprávy lesnického výzkumu 53. s 165 – 178.
- LOMSKÝ, B.; ŠRÁMEK, V. (2004).** Damage of the forest stands in the ORE Mts. During the period 1995 – 1997. J. For. Sci., 45. s. 169 – 180.
- LOMSKÝ, B.; ŠRÁMEK, V.; NAVRÁTIL, P.; BALCAR, V.; SMEJKAL, J.; MATĚJKA, K.; HADAŠ, P. (2007).** Výzkumné projekty. Grantové služby LČR. Lesnické hospodaření v imisní oblasti Krušných hor: Vývoj poškození lesních porostů. Vol. 1. s. 3-4.
- LIPTON, Z.C.; ELKAN, CH.; NARYANASWAMY, B. (2014).** Thresholding Classifiers to Maximize F1 score. San Diego.
- MITCHELL, T. (1997).** Machine learning. Chapter 1 – Introduction. New York. 414 s. ISBN 0-07-042807-7.
- MOSKAL, L.M.; ZHENG, G. (2012).** Retrieving forest inventory variables with terrestrial laser scanning (TLS) in urban heterogeneous forest. Remote Sens. 4. s. 1–20.
- PEŠKOVÁ, V.; MODLINGER, R. (2014).** K poškození modřínu v Krušných horách v roce 2014. Lesnická práce 93 (12). s. 46 – 47.
- PEŠKOVÁ, V.; MODLINGER, R. (2015).** Stav napadení smrku pichlavého a ztepilého kloubnatkou smrkovou. Lesnická práce. Vol. 3. s. 48 – 49.
- PEŠKOVÁ, V.; MODLINGER, R.; SAMEK, R.; VÉLE, A. (2019).** Kloubnatka smrková na smrku ztepilém v Jizerských horách a Krkonoších . s. 22 – 23.
- PEŠKOVÁ, V.; SOUKUP, F. (2013).** Současná situace v porostech smrku pichlavého v Krušných horách. Lesnická práce, 92 (10). s. 46 – 47.
- PETRZIK, K.; KOLONIUK, I.; SARKISOVA, T.; HRABAKOVA, L. (2016).** Detection and genome sequence of a new betapartitivirus joined with Cucurbitaria piceae

Borthw. fungus causing bud blight of spruce in the Czech Republic. Archives of Virology.

PRŮŠA, E. (2001). Pěstování lesů na typologických základech. Lesnická práce. 1. vyd. Kostelec nad Černými lesy. s. 426. ISBN 80 – 86386 – 10 – 4.

PUTTONEN, W.; MANDLBURGER, G.; BRIESE, C.; ZLINSZKY, A. Quantification of Overnight Movement of Birch (*Betula pendula*) Branches and Foliage with Short Interval Terrestrial Laser Scanning. Frontiers in Plant science.. Česká republika (Praha). [s. n.], 2016 [cit. 2021-04-25]. Dostupné z WWW: <<https://www.frontiersin.org/articles/10.3389/fpls.2016.00222/full>>.

R CORE TEAM. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria, 2020, Dostupné z WWW: <<https://www.R-project.org/>>.

SAHA, S. A comprehensive guide to Convolutional Neural Networks – the ELI5 way. Towards Data Science. [s. n.], 2018 [cit. 2022-04-08]. Dostupné z WWW: <<https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>>.

SARKER, N.; HAQUE, I.; UDDIN, N. (2020). Leaf disease detection using Deep learning. Bangladesh.

Seko, L. (1998). Geografia pre 4

SHAKYA, A.; BISWAS, M.; PAL, M. (2021). Parametric study of convolutional neural network based remote sensing image classification. International Journal of remote sensing. Volume 42.

SCHMIDHUBER, J. (2015). Deep Learning in Neural Networks: An Overview. Neural Networks. Vol. 61. s. 85 – 117.

SIMON, L.; WEBSTER, R.; RABIN, J. (2019). Revisiting Precision and Recall Definition for Generative Model Evaluation. California. Vol. 97.

SMEJKAL, J. Natural conditions. **IN LOMKŠÝ, B.; MATERNA, J.; PFANZ, H. (2002).** SO₂ – Pollution and forests decline in the Ore mountains. 1. vyd. Jiloviště – Strnady. VÚLHM. 342. s. ISBN 80 – 86461 – 24 – 6.

STRNADOVÁ, V. Charakteristika sledovaných dřevin. **IN GREGOROVÁ, B. ; TÁBOR, I.; JANČAŘÍK, V. ; ČERNÝ, K. ; HOLUB, V. ; STRNADOVÁ, V. ; ROM, J. ; ŠUMPICH, J. ; KLOUDOVÁ, K. (2006).** Poškození dřevin a jeho příčiny. 1 vyd. Praha. ZO ČSOP. s. 57 – 58. ISBN 80-85116-45-X.

- SUROVÝ, P.; KUŽELKA, K.; ABDOLAHNEJAD, A.; SIROTKOVÁ, K.; MELICHOVÁ, Z. (2019).** Aplikace dálkového průzkumu země v lesnictví. 1. vyd. Praha: Česká zemědělská univerzita v Praze. s. 65 – 198 . ISBN 978-80-213-3008-5.
- SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCKE, V.; RABINOVICH, A. (2015).** Going deeper with convolutions proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. s. 1-9.
- ŠRÁMEK, V. (1998).** SO₂ air pollution and forest health status in northwestern Czech Republic. Chemosphere, 36. s. 1067 – 1072.
- TRAVELLETTI, J.; OPPIKOFER, T.; DELACOURT, C.; MALET, J.P.; JABEYODEFF, M. (2008).** Monitoring landslide displacements during a controlled rain experiment using a long-range Terrestrial Laser Scanning (TLS),” in International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, eds J. Chen, J.Jiang, and H.-G.Maas (Beijing: International Society for Photogrammetry and Remote Sensing). s. 485–490.
- TZUTALIN, D. (2015).** LamellImg. GitHub Repository 6.
- VALUEVA, M.V.; NAGORNOV, N.N.; LYAKHOV, P.A.; VALUEV, G.V.; CHERVYAKOV, N. I. (2020).** Application of the residue number system to reduce hardware costs of the convolutional neural network implementation. Mathematics and Computers in Simulation. Vol. 177. s. 232 – 243.
- VERZANI, J. (2011).** Getting Started with R studio. CA. Sebastopol. s. 1 – 7. ISBN 978 – 1 – 449 – 30903 – 9.
- WALLACE, L.; ARKO, L.; MALENOVSKÝ, Z.; TURNER, D.; VOPĚNKA, P. (2016).** Assesment of Forest Structure Using Two UAV Techniques: A Comparison of Airborne Laser Scanning and Structire form Motion (SfM) Point Clouds. Forests 7 (3). s. 1 -16.
- WANG, CH.F.** A basic Indtroduction to Separable Convolutions. Toward Data Science. [s. n.], 2018 [cit. 2022-04-08]. Dostupné z WWW: <<https://towardsdatascience.com/a-basic-introduction-to-separable-convolutions-b99ec3102728>>.
- YACOUBY, R.; AXMAN, D. (2020).** Probablilistic Extension of Precision, Recall and F1 Score for More Thorough Evaluation of Classification of Models. Vol. 1. s. 79 – 91.

QINGJIE, Z.; JIAOLONG, X.; LIANG, X. HAIFENG, G. (2016). Deep Convolutional Neural Networks for Forest fire Detection. International Forum on Management, Education and Information Technology Application (IFMEITA 2016). Changchun. China

ZÝKA, V.; ČERNÝ, K.; STRNADOVÁ, V.; ZAHRADNÍK, D.; HRABĚTOVÁ, M.; HAVRDOVÁ, L.; ROMPORTL. D. (2018). Predikce poškození porostů smrku pichlavého kloubnatkou smrkovou v Krušných horách. Mapa s odborným obsahem, VÚKOZ, v. v. i. Certifikováno Ministerstvem zemědělství ČR. Průhonice. ISBN 978 – 80 – 87674 – 29 – 1.

8. Prílohy



Príloha 1: Príklad nekrotizovaného púčiku (naľavo), odumretého púčiku pokrytého plodnicami (uprostred) a zdravého púčiku (na pravo) (Zdroj: Zýka, 2018)



Príloha 2: po silnom napadnutí púčiky odumierajú a staré ročníky ihlíc už nie sú nahradzované (Zdroj: Zýka, 2019)



Príloha 3: Tvorbou adventných púčikov dochádza k výraznej deformácii (Zdroj: Soukup & Pešková, 2009)



Príloha 4: Detailný záber na plodnice (Zdroj: Zbirová, 2019)