

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE
FAKULTA ŽIVOTNÍHO PROSTŘEDÍ
KATEDRA APLIKOVANÉ GEOINFORMATIKY A ÚZEMNÍHO
PLÁNOVÁNÍ



**KLASIFIKACE OBRÁZKOVÝCH DAT PRO ÚČELY
DETEKCE STROMŮ NAPADENÝCH LÝKOŽROUTEM
SMRKOVÝM**

DIPLOMOVÁ PRÁCE

Diplomant: Bc. Hana Klápšťová
Vedoucí práce: Ing. Jan Komárek, Ph.D.

2019

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Hana Klápšťová

Krajinné a pozemkové úpravy

Název práce

Klasifikace obrazových dat pro účely detekce stromů napadených lýkožroutem smrkovým

Název anglicky

Classification of UAV-borne imagery for detection of bark beetle infestation

Cíle práce

Cílem práce je detekce napadených stromů lýkožroutem smrkových na vybrané lokalitě za využití obrazových dat pořízených bezpilotním prostředkem. Dílčím cílem je ověření kvality klasifikačních algoritmů, za účelem rozlišení napadených, zdravých a mrtvých stromů. Cílem je také posouzení možnosti využití software eCognition Developer ke zpracování tohoto typu dat.

Metodika

Autorka využije obrazová data pořízená bezpilotním systémem nad vybranou zájmovou lokalitou a analýzou obrazu rozliší zdravé, napadené a mrtvé stromy s využitím profesionálního software. Autorka využije možnosti řízených klasifikačních přístupů a analyzuje časovou řadu dat. Vhodným způsobem budou pro účely klasifikace vytvořeny trénovací a validační vzorky stromů. Úspěšnost klasifikace bude validována a vyhodnocena pomocí chybové matice.

Doporučený rozsah práce

40 – 60 normostran

Klíčová slova

UAV, dron, multispektrální data, kůrovec, analýza obrazu

Doporučené zdroje informací

- Abdullah, H.; Darvishzadeh, R.; Skidmore, A. K.; Groen, T. A.; Heurich, M. European spruce bark beetle (*Ips typographus*, L.) green attack affects foliar reflectance and biochemical properties. *Int. J. Appl. Earth Obs. Geoinf.* 2018, 64, 199–209, doi:10.1016/j.jag.2017.09.009.
- Brovkina, O., Cienciala, E., Surový, P., Janata, P., 2018. Unmanned aerial vehicles (UAV) for assessment of qualitative classification of Norway spruce in temperate forest stands. *Geo-Spatial Inf. Sci.* 21, 12–20. doi:10.1080/10095020.2017.1416994.
- Fassnacht, F. E.; Latifi, H.; Ghosh, A.; Joshi, P. K.; Koch, B. Assessing the potential of hyperspectral imagery to map bark beetle-induced tree mortality. *Remote Sens. Environ.* 2014, 140, 533–548, doi:10.1016/j.rse.2013.09.014.
- Minařík, R., Langhammer, J., 2016. Use of a multispectral UAV photogrammetry for detection and tracking of forest disturbance dynamics. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. – ISPRS Arch.* 41, 711–718. doi:10.5194/isprsarchives-XLI-B8-711-2016.
- Näsi, R.; Honkavaara, E.; Lyytikäinen-Saarenmaa, P.; Blomqvist, M.; Litkey, P.; Hakala, T.; Viljanen, N.; Kantola, T.; Tanhuanpää, T.; Holopainen, M. Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level. *Remote Sens.* 2015, 7, 15467–15493, doi:10.3390/rs71115467.
- Stoyanova, M., Kandilarov, A., Koutev, V., Nitcheva, O., 2018. Potential of multispectral imaging technology for assessment coniferous forests bitten by a bark beetle in Central Bulgaria 1005. doi:10.1051/mateconf/201814501005.
-

Předběžný termín obhajoby

2018/19 LS – FŽP

Vedoucí práce

Ing. Jan Komárek, Ph.D.

Garantující pracoviště

Katedra aplikované geoinformatiky a územního plánování

Konzultant

Ing. Jiří Prošek (eCognition)

Elektronicky schváleno dne 14. 3. 2019

doc. Ing. Petra Šímová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 14. 3. 2019

prof. RNDr. Vladimír Bejček, CSc.

Děkan

V Praze dne 18. 04. 2019

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně pod vedením Ing. Jana Komárka, Ph.D., a že jsem uvedla všechny literární prameny, ze kterých jsem čerpala.

Prohlašuji, že tištěná verze se shoduje s verzí odevzdanou přes Univerzitní informační systém

V Praze dne 18. 4. 2019

.....
Hana Klápšťová

Poděkování

Ráda bych touto cestou poděkovala Ing. Janu Komárkovi Ph.D. za vedení práce, cenné rady a připomínky při jejím zpracování, dále Ing. Jiřímu Proškovi, který mi poskytl odborné rady při zpracování dat v programu eCognition a v neposlední řadě své rodině za podporu během celého studia.

Abstrakt

V současné době se lesní hospodářství potýká s velkou hrozbou, kterou představuje přemnožení kalamitního škůdce lýkožrouta smrkového (*Ips typographus*). Tato práce se zabývá testováním metod pro detekci stromů napadených lýkožroutem smrkovým za využití obrázkových dat pořízených bezpilotním prostředkem a ověřením kvality použitých klasifikačních algoritmů, které rozlišují napadený, zdravý a mrtvý strom. Sledovaná lokalita byla zvolena v bezzásahovém území Krkonošského národního parku v oblasti Pece pod Sněžkou, kde neprobíhá zásah proti kůrovci a je zde možnost sledovat změny porostu v průběhu celého vývoje lýkožrouta smrkového. Celý proces pro objektově orientovanou analýzu obrazu lesního porostu se skládá ze segmentace a následné klasifikace na základě charakteristik jednotlivých segmentů. Pro tuto práci byla zvolena řízená klasifikace pomocí Nearest Neighbour (NN) a Classification Tree (Decision Tree) klasifikátoru. K hodnocení úspěšnosti a ke stanovení vlastností klasifikace slouží výpočet klasifikační chybové matice, která porovnává vztah mezi validačními daty a výsledky klasifikace. Výsledky práce ukázaly, že tato klasifikace je možná na základě obou zvolených algoritmů. Nejlepší variantou pro obě klasifikace je kombinace dat z prvního a posledního náletu, kdy při NN algoritmu jsou výsledky pro celkovou přesnost 85,7 %, Producer's a User's Accuracy napadených stromů 80 % a koeficient Cohen's Kappa 0,74. Při použití Decision Tree algoritmu pro kombinaci dat z prvního a posledního náletu jsou výsledky pro celkovou přesnost 72,2 %, Producer's Accuracy 53 % a User's Accuracy 40 % pro napadené stromy. Koeficient Cohen's Kappa je v tomto případě 0,52. V současnosti lze tuto práci využít ke sledování změn zdravotního stavu jednotlivých stromů i celých porostů a může sloužit jako metodika pro použití softwaru eCognition Developer ke klasifikaci napadených stromů s využitím dat z UAV.

Klíčová slova: analýza obrazu, kůrovec, multispektrální data, UAV

Abstract

Forestry is currently faced with a great threat posed by the overpopulation of the mass pest species bark beetle (*Ips typographus*). This thesis focuses on testing different methods of detecting trees invaded by the bark beetle through the use of imagery from an unmanned aerial vehicle (UAV) and through validating the quality of the classification algorithms which distinguish among invaded, healthy, and dead trees. The monitored locality was chosen in a non-intervention territory of the Krkonoše Mountains National Park, in the Pec pod Sněžkou area, where the zero intervention against the bark beetle enables the monitoring of the forest cover changes throughout the entire development cycle of the bark beetle. For an object-oriented analysis of the forest cover image, the whole process consists of segmentation and subsequent classification based on the characteristics of individual segments. For this thesis we have chosen a controlled classification using the Nearest Neighbour (NN) and Classification Tree (Decision Tree) classifiers. For success rate assessment and for the classification features selection we used the calculation of a classifying error matrix, which compares the relation between the validation data and the classification results. The results of this work show that this classification is possible on the basis of both selected algorithms. The best option for both classifications is the combination of the first and the last UAV data, in which the overall accuracy result for the NN algorithm is 85,7 %, the Producer's and User's Accuracy of the invaded trees is 80 %, and the Cohen's Kappa coefficient is 0,74. For the Decision Tree algorithm, when combining the first and the last UAV data, the overall accuracy result is 72,2 %, for Producer's Accuracy 53 % and for User's Accuracy 40 % for the invaded trees. The Cohen's Kappa coefficient is in this case 0,52. This thesis can currently be used for the monitoring of changes in the health condition of individual trees as well as entire forest covers, and can serve as a methodology for the use of the eCognition Developer software in the classification of invaded trees by means of UAV.

Keywords: bark beetle, image analysis, multispectral data, UAV

Obsah

Seznam použitých zkratk	10
1. Úvod	11
2. Cíle práce	13
3. Literární rešerše	14
3.1 Dálkový průzkum Země	14
3.1.1 Spektrum elektromagnetického vlnění	15
3.1.2 Spektrální chování objektů.....	17
3.1.3 Spektrální chování vegetace.....	18
3.1.4 Spektrální indexy.....	19
3.2 Klasifikace obrazu	20
3.3 Fotogrammetrie	22
3.4 Bezpilotní letecké prostředky v DPZ	23
3.4.1 Multikoptéry.....	24
3.4.2 Křídlo	25
3.4.3 Legislativní opatření.....	27
3.5 Krkonošský národní park	27
3.5.1 Lesní hospodářství na území KRNAP.....	29
3.6 Lýkožrout smrkový	29
3.6.1 Popis a taxonomické zařazení	30
3.6.2 Vývojový cyklus, bionomie	30
3.7 Přehled současného stavu řešení	32
4. Metodika	34
4.1 Zájmové území	34
4.2 Použité UAV pro monitoring zájmového území	35

4.3	Zpracování dat.....	35
4.3.1	Hodnocení přesnosti klasifikace.....	39
5.	Výsledky.....	40
6.	Diskuze.....	43
6.1	Doporučení pro další využití.....	44
7.	Závěr	45
8.	Přehled literatury a použitých zdrojů.....	46
9.	Seznam obrázků a tabulek.....	51
10.	Přílohy.....	53

Seznam použitých zkratk

DEM	Digitální výškový model (Digital elevation model)
DPZ	Dálkový průzkum Země
GNDVI	Zelený normalizovaný diferenční vegetační index (Green Normalized Difference Vegetation Index)
IR	Infračervené záření (Infrared)
KRNAP	Krkonošský národní park
MWIR	Střední infračervené záření (Mid-wavelength infrared)
NDVI	Normalizovaný diferenční vegetační index (Normalized Difference Vegetation Index)
NIR	Blízké infračervené záření (Near-Infrared)
NN	Nearest Neighbour
RGB	Červená Zelená Modrá (Red Green Blue)
RPA	Remotely Piloted Aircraft
RVI	Jednoduchý poměrový vegetační index (Ratio Vegetation Index)
SWIR	Krátké infračervené záření (Short-wavelength infrared)
TIFF	Tag Image File Format
TIR	Tepelné infračervené záření (Thermal-Infrared)
UAS	Bezpilotní letecký systém (Unmanned Aerial Systems)
UAV	Bezpilotní letecký prostředek (Unmanned Aerial Vehicle)

1. Úvod

Přírodní podmínky a poměry se člověk od pradávna snaží využívat pro své potřeby a existenci. V důsledku toho dochází v průběhu vývoje života na Zemi k výrazným změnám. Je tomu tak i v několika posledních stoletích, kdy člověk svou činností výrazně ovlivňuje celé ekosystémy až do dnešní podoby. Mezi nejzávažnější antropogenní vlivy působící na přírodní prostředí lesních porostů patří odlesňování s následným vznikem bezlesí, velkoplošná změna původních lesních ekosystémů na stejnověkové smrkové monokultury často nevhodného genetického původu a imisní zátěž.

Vývoj lesů v Krkonošském národním parku byl nejvíce ovlivněn člověkem v průběhu 15. století při kolonizaci. Došlo k zásahu do souvislých lesních porostů a v polovině 16. století s rozvojem důlního podnikání docházelo k rozsáhlým těžbám dříví pro potřebu kutnohorských dolů. Z tohoto důvodu byly na počátku 17. století všechny původní lesní porosty zejména v oblasti středních a východních Krkonoš odtěženy (Flousek, 2007). To způsobilo úbytek původní přirozené skladby lesních porostů, kde byl zastoupen buk a jedle, a došlo k obnově lesů se smrkovou monokulturou. Plošné změny věkové a druhové struktury porostů, které byly podmíněny rozsáhlými plošnými těžbami spolu s preferencí smrkové monokultury, se později projeví narušením ekologické stability lesů. Důsledkem zásahů do lesních porostů byly i rozsáhlé holiny, které vznikly abiotickými činiteli, tedy především sněhovými a větrnými kalamitami. K narušeným lesním porostům se přirozeně váže i zvýšený výskyt hmyzích škůdců, obzvláště z čeledi kůrovcovitých. Na takto obhospodařovaných plochách, které jsou obnovovány později nevhodným způsobem, jsou dnes k vidění rozsáhlé smrkové porosty s minimálním zastoupením jiných druhů dřevin. Velké části porostů jsou vystavovány mnoha stresovým faktorům, zejména suchu, nedostatku živin v půdě, hmyzím škůdcům, ale také patogenním mikroorganismům způsobující choroby. Oslabené porosty se dále již nedokáží bránit, a jsou atraktivním lákadlem pro další vývoj kalamitních škůdců, kterým je především lýkožrout smrkový (*Ips typographus*).

V současné době jsou ohroženy kůrovcem lesy po celé České republice, a proto je nutné zahájit opatření, které zabrání jeho dalšímu šíření. Důležitou preventivní metodou zamezení přemnožení kůrovce je včasná detekce napadených stromů a jejich asanace.

Pokud však nedokážeme zpracovat dříví a stojící stromy napadený kůrovcem včas, může dojít ke vzniku kůrovcové kalamity. Na plochách, které jsou postiženy kůrovcovou kalamitou, se používají klasické metody, jako je fyzická pochůzka porostem a vyznačování napadených stromů, avšak tato metoda je z časového a personálního hlediska náročná. Mnohdy ani zkušený pracovník v oblasti lesního hospodářství nerozpozná stojící, kůrovcem napadený strom. Právě v těchto případech je vítanou možností využití moderních technologií k včasné detekci napadených stromů. Jednou z možností sloužící k vyhledávání napadených stromů je využití bezpilotních prostředků tzv. dronů, nesoucí na sobě různá záznamová zařízení, kterými jsou např. infrakamery, multispektrální kamery nebo jakékoliv přístroje pro fotogrammetrii, sloužící k dálkovému průzkumu Země.

Právě tato práce se zabývá testováním možností pro detekci stromů napadených lýkožroutem smrkovým při využití dat z UAV. Jejím cílem je ověřit přesnost použitých klasifikačních algoritmů, které rozlišují napadené, zdravé a mrtvé stromy. Dílčím cílem je porovnání použitých klasifikačních algoritmů a vyhodnocení možnosti užití softwaru eCognition Developer ke zpracování tohoto typu dat.


2. Cíle práce

Cílem této diplomové práce je testování metod pro detekci napadených stromů lýkožroutem smrkovým na vybrané lokalitě za využití obrazových dat pořízených bezpilotním prostředkem. Dílčím cílem je ověření kvality klasifikačních algoritmů, za účelem rozlišení napadených, zdravých a mrtvých stromů. Dalším dílčím cílem je porovnání dvou klasifikačních algoritmů, které byly použity pro tuto práci. Posledním cílem je posouzení možnosti využití softwaru eCognition Developer ke zpracování tohoto typu dat.

3. Literární rešerše

3.1 Dálkový průzkum Země

Dálkový průzkum Země je metoda, která slouží k získávání informací o objektech a jevech na povrchu planety Země bez přímého fyzického kontaktu, tedy na dálku a to za pomoci speciálních zařízení. Při tomto procesu dochází k zajištění kvantitativních a kvalitativních údajů o zkoumaných objektech (Dobrovolný, 1998). Jelikož v DPZ nedochází k přímému kontaktu s měřeným objektem, jsou měřicí senzory umístěny na různých platformách (Žížala et al., 2016). DPZ je znám v anglicky psané literatuře jako Remote Sensing a je řazen mezi tzv. geoinformační technologie, tedy technologie, které umožňují o daném objektu informace získávat, dále je zpracovat a následně ukládat, analyzovat a vyhodnocovat. Data DPZ jsou vytvořeny za pomoci různých prostředků např. družice, letadlo a dron. Výsledkem DPZ jsou zejména družicové scény, letecké snímky a fotografie (Svatoňová & Lauermaun, 2006, 2010).



Obrázek 1: Schéma elektromagnetické vlny (Dobrovolný, 1998).

DPZ získává informace o objektech a jevech prostřednictvím elektromagnetického záření. Energie tohoto záření spočívá ve vlnění, šíří se tedy prostorem ve tvaru tzv. elektromagnetické vlny. Elektromagnetická vlna se skládá ze dvou komponentů – elektrického pole a magnetického pole (Obrázek 1). Obě tyto vlny spolu svírají pravý úhel, jsou rovnoběžné ve směru šíření a šíří se rychlostí světla (c). Základními charakteristikami elektromagnetického záření je vlnová délka (λ) a frekvence (ν). Vlnová délka je vzdálenost dvou sousedních vrcholů vlny. Frekvence je potom počet vrcholů vlny procházejících

fixním bodem za jednotku času. Vlnová délka se měří v metrech (m) popřípadě v jiných odvozených jednotkách, frekvence se měří v Hertzech (Hz). Mezi frekvencí a vlnovou délkou je nepřímá úměra: $\lambda = c / \nu$ (Dobrovolný, 1998).

Elektromagnetické záření je pohlcováno nebo odráženo všemi objekty, které mají teplotu vyšší než je absolutní nula (-273,5 °C). Původem tohoto záření může být Země nebo Slunce. Zdroje měřeného záření lze rozdělit na aktivní, které využívají umělého zdroje záření (radary a lasery) nebo pasivní, kdy je měřeno přírodní záření, tj. tepelné záření emitované objektem nebo odražené sluneční záření (Kolář, 1989). Vlivy atmosféry na charakteristiky elektromagnetického záření se mění s délkou dráhy, kterou záření prochází atmosférou, s velikostí emitovaného signálu, atmosférickými podmínkami a také s vlnovou délkou. Podle Dobrovolného (1989) má tedy atmosféra (částice a plyny) velký vliv na intenzitu a spektrální složení záření, které je následně zachyceno měřicím zařízením.

3.1.1 Spektrum elektromagnetického vlnění

Elektromagnetická záření různých vlnových délek tvoří spektrum elektromagnetického záření. Celé toto spektrum je podle frekvence rozděleno na několik druhů, které jsou popsány, a graficky znázorněné viz Obrázek 2.


Infračervené záření (IR) je charakterizováno vlnovými délkami od 1 mm do 0,72 μm (mikrometr). Toto záření lze rozdělit do 4 pásem – blízké IR s vlnovým rozsahem 0,72 - 1,3 μm ; střední IR s vlnovým rozsahem 1,3 - 4 μm ; daleké IR (teplotní) s vlnovým rozsahem 4 - 25 (~300) μm a submilimetrové vlny s vlnovým rozsahem $> \sim 100 \mu\text{m}$ (Halounová & Pavelka, 2005).

Oblast blízkého infračerveného záření (NIR) tvoří pokračování atmosférického okna z viditelné části spektra, toto záření se tedy chová podobně. Lze je zaznamenávat jak konvenčními fotografickými metodami, tak elektronicky. Je již méně pohlcováno a rozptylováno atmosférou. Hodí se k topografickým účelům, důležité jsou tyto vlnové délky pro studium vegetace především v zemědělství a lesnictví. Např. voda se v těchto vlnových délkách chová téměř jako absolutně černé těleso.

Oblast středního infračerveného záření (MWIR) zahrnuje dvě atmosférická okna se středy okolo 1,5 μm a 2,2 μm . Obě jsou důležité především pro vegetační a geologické

studie. V blízké i střední části elektromagnetického spektra je množství odraženého záření výrazně větší, než množství záření emitovaného. V důsledku malého množství emitovaného záření nelze blízké ani střední infračervené vlnové délky využít k zjišťování teplotních vlastností povrchu, to je možné až v oblasti termálního infračerveného záření, kde je podíl emitovaného záření větší.

Oblast tepelného infračerveného záření (TIR) obsahuje dvě atmosférická okna v intervalu 3 – 5 μm a 8 – 12 μm . V tomto rozsahu lze přesně kalibrovanými senzory získávat poznatky o tepelné bilanci objektů. Používají se například k zjišťování povrchové teploty oceánů, k mapování tepelného znečištění řek, jezer i samotné krajiny.



Obrázek 2: Rozdělení elektromagnetického spektra (Homolová et al., 2014).

Viditelné záření je charakterizováno rozsahem vlnových délek v rozmezí 380 nm – 720 nm. Viditelné záření lze schématicky dělit na část modrého světla (0,4 μm – 0,5 μm) zeleného světla (0,5 μm – 0,6 μm) a červeného světla (0,6 μm – 0,7 μm). Viditelné záření ovlivněné aerosoly je poměrně značně pohlcováno a rozptylováno, není schopné projít mlhou a oblačností, avšak v suché a čisté atmosféře je ovlivňováno velmi málo. Zdrojem tohoto krátkovlnného záření je Slunce, lze ho tedy zaznamenávat jen v denních hodinách. Ve srovnání s dalšími vlnovými délkami je toto záření schopno procházet vodním sloupcem, především v modré části spektra (Dobrovolný, 1989). Cracknell & Hayes (1993)

uvádějí, že modré světlo může pronikat čistou vodou v oceánu do hloubek 20 – 30 metrů, zatímco v červené části viditelného spektra je záření vodou výrazně pohlcováno. Tento jev umožňuje studovat mnoho biologických i fyzikálních vlastností vodních objektů.

3.1.2 Spektrální chování objektů

Sluneční záření, které dopadá na zemský povrch je z části vedeno do nižších vrstev, zčásti absorbováno a z části odraženo a vráceno nazpět do atmosféry. K modifikaci záření dochází jak při průchodu atmosférou, tak na své cestě na zpět po odrazu, ale i při dopadu na zemský povrch. Intenzita odraženého krátkovlnného záření, ale i intenzita emitovaného záření dlouhovlnného je podmíněna především těmito faktory:

- druh látky či objektu (např. na jeho chemickém složení, apod.)
- fyzikální stav (např. vlhkost, zhutnění povrchu, apod.)
- stav jeho okolí (např. propustnost atmosféry, apod.)


Dobrovolný (1998) uvádí, že množství odraženého záření lze charakterizovat tzv. spektrální odrazivostí $\rho(\lambda)$. Tu lze popsat jako poměr intenzity odraženého záření (M_r) a intenzity záření dopadajícího (M_i) na určité vlnové délce (λ) udávaný např. v procentech.

Přes všechny výše zmíněné vlivy lze konstatovat, že každá látka na zemském povrchu se vyznačuje svoji vlastní spektrální charakteristikou. Když dojde k porovnání snímků stejné krajiny, pořízených v různých částech elektromagnetického spektra, je zřejmé, že některé objekty jsou dobře rozpoznatelné na snímcích ve viditelné části spektra a jiné v části infračerveného spektra. Viditelnost objektu na daném snímku je dána množstvím odraženého záření. Když objekt odráží málo světla, jeví se na snímku jako tmavý a naopak (Dobrovolný, 1998).

3.1.3 Spektrální chování vegetace

Rostliny se vyznačují specifickou odrazivostí v jednotlivých pásmech elektromagnetického záření. Červená a modrá část záření je spotřebována v průběhu fotosyntézy, zatímco zelená část spektra je odrážena. Z tohoto důvodu se nám rostliny jeví jako zelené.

Blízké infračervené spektrum odráží většinu záření a je pro lidské oko neviditelné, proto je potřeba speciálních detekčních zařízení pro jeho záznamy. Odrazivost ve viditelném záření podává informaci o stavu fotosyntetického aparátu. U rostlin trpících stresem (nebo u stárnoucích rostlin) se odrazivost mění, v červeném spektru odrazivost přibývá (rostliny žloutnout) a naopak se v pásmu NIR odrazivost snižuje. Tento princip, při kterém dochází k porovnávání odrazivosti v jednotlivých spektrech, je využíván velkou většinou přístrojů, které slouží k hodnocení stavu porostů. Sensorové měření dokáže spolehlivě určit rozdíly v porostu, které jsou způsobeny např. nedostatečnou výživou, vodním stresem, napadením rostlin škůdce, apod. Nejsou však schopny určit přesnou příčinu identifikovaného stresu (Lukas et al., 2011) (Obrázek 3).



Obrázek 3: Schopnost listů odrážet různé formy světla v závislosti na zdravotním stavu dřeviny. Dostupné z: <<http://www.innovativegis.com/basis/pfprimer/topic7/topic7.html>>

Lehmann (2015) využil infračervené spektrum při zjišťování stupňů poškození u dubových porostů. Určoval defoliaci pomocí infračerveného barevného spektra (CIR), které zobrazovalo odrazivost korun stromů na úrovni větví. U napadených dubů využil blízké infračervené spektrum.

3.1.4 Spektrální indexy

Vegetační indexy, označovány též jako spektrální indexy zahrnují skupinu relativně jednoduchých aritmetických operací se dvěma či více pásmy multispektrálního obrazu. Cílem těchto operací je na základě znalosti spektrálního chování zvýraznit například vegetační složku na snímku. Tyto indexy lze využít i k určení kvantitativních ukazatelů, jako je např. množství (hmotnost) zelené biomasy na ploše pixelu apod. Spektrální indexy lze rozdělit do dvou skupin: poměrové indexy a ortogonální indexy. Poměrové indexy dávají do vztahu odrazivost povrchů v červené viditelné části spektra a blízké infračervené části spektra.

Jednoduchý poměrový vegetační index (RVI – Ratio Vegetation Index):

$$RVI = \frac{NIR}{RED}$$

Normalizovaný diferenční vegetační index (NDVI - Normalized Difference Vegetation Index):

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

NDVI je nejpoužívanějším poměrovým indexem. Jeho hodnoty se mohou pohybovat v intervalu od - 1 do + 1 a souvisí především s obsahem zelené hmoty na ploše pixelu. Záporné hodnoty vypovídají o malém množství zelené hmoty a kladné vyjadřují opak. Typické hodnoty NDVI jsou např.: hustá vegetace 0,5; řídká vegetace 0,09; holá půda 0,025; sníh a led -0,046 a voda -0,257. Hodnoty NDVI pro určité povrchy procházejí změnami i v průběhu roku, čehož se využívá hlavně v zemědělství a lesnictví. Z hodnot NDVI lze určit zdravotní stav vegetace (Dobrovolný, 1998).

3.2 Klasifikace obrazu

Dobrovolný (1998) uvádí, že klasifikace obrazu je proces, při kterém je jednotlivým obrazovým prvkům přiřazován konkrétní informační význam. Cílem je nahradit hodnoty radiometrických charakteristik původního obrazu, který vyjadřuje spektrální vlastnosti objektů, hodnotami vyjadřující tzv. informační třídy. Informační třídy jsou definovány na začátku procesu celé klasifikace a objeví se v legendě výsledné mapy. Jednotlivé prvky se člení do tříd, ke kterým se využívají určitá rozhodovací pravidla – klasifikátory. Nejčastěji se používají klasifikátory založené na spektrálním chování objektů. Existuje různé dělení klasifikace, ovšem mezi nejčastěji používané patří klasifikace řízená a neřízená.

Pro řízenou klasifikaci (z angl. Supervised Classification) je důležitá znalost oblasti klasifikovaného snímku. V porovnání s neřízenou klasifikací jsou metody řízené klasifikace vyžadovány od uživatele předtím, než je aplikován zvolený algoritmus. Tyto metody vycházejí především z analýz leteckých fotografií, terénních šetření nebo ze studií vhodných map oblasti zájmu. Řízené klasifikace jsou implementovány prostřednictvím statistických nebo nestatistických algoritmů. Statistické algoritmy využívají parametrů odvozených ze vzorových dat ve formě tréninkových tříd. Jsou to například maximální a minimální hodnoty prvků, průměrné hodnoty jednotlivých klastrů, průměr či variační-kovariační matice pro každou třídu. Nestatistické algoritmy jsou naopak přímo trénovány na ukázkových datech a nespolehají se na statistické informace, které jsou odvozené ze vzorových dat (Mather & Koch, 2011).

Cílem první fáze řízené klasifikace je vymezení tzv. trénovacích ploch pro každou třídu, která by měla být na snímku identifikována. Trénovací etapa je klíčová pro úspěšné provedení celé klasifikace, proto musí být kompletní a reprezentativní. Důležité je, aby trénovací plochy byly homogenní. Pro vzorek, který vznikne z trénovacích ploch, jsou vypočteny statistické charakteristiky každé třídy, které určují vhodnost trénovacích ploch a jejich vzájemnou separabilitu.

Po výpočtu spektrálních příznaků pro dané trénovací plochy je nutné vybrat vhodné rozhodovací pravidlo (klasifikátor), podle kterého budou všechny obrázkové prvky rozřazeny do jednotlivých informačních tříd. Klasifikátorů existuje několik, k nejčastěji používaným však patří:

- klasifikátor minimální vzdálenosti středu shluků (angl. Minimum Distance)

Fungování tohoto klasifikátoru je založeno na takovém principu, že pro každý shluk je vypočtena průměrná spektrální hodnota v každém klasifikovaném pásmu, průměrné hodnoty definují střed shluku (centroid), jednotlivé pixely jsou následně přiřazeny tomu shluku, jehož střed je v multidimenzionálním prostoru nejbližší.

- klasifikátor maximální pravděpodobnosti (angl. Maximum Likelihood)

Následkem vnitřních a vnějších vlivů může docházet k tomu, že se shluky v příznakovém prostoru buď překrývají, nebo jsou jejich středy vzdáleny stejně daleko. Důsledkem může být problematické zařazení jednotlivých pixelů do správných shluků. Klasifikátor maximální pravděpodobnosti kvantitativně hodnotí rozptyl, korelaci a kovarianci každé třídy při zařazování neznámého pixelu. Předpokládá též normální rozdělení hodnot, ze kterého lze sestavit frekvenční funkce. Pro všechny hodnoty na horizontální ose lze vypočítat pravděpodobnost její příslušnosti k danému rozdělení.

- klasifikátor „K“ nejbližších sousedů (angl. Nearest Neighbour - NN)

Toto rozhodovací pravidlo je modifikací klasifikátoru minimální vzdálenosti. Posuzuje příslušnost daného pixelu k určité třídě nejen na základě jeho vzdálenosti od středu shluku, ale také na základě aritmetického zastoupení pixelů konkrétní třídy v okolí zpracovaného obrazového prvku. Algoritmus vyhledá klasifikovanému pixelu předem stanovený počet (K) nejbližších pixelů, bez ohledu na trénovací množiny. Pixel je poté přiřazen do třídy, která v množině K sousedů převažuje (Dobrovolný, 1998).

Neřízená klasifikace (z angl. Unsupervised Classification) nevyžaduje znalost vlastností daných tříd a tvorbu trénovacích ploch. U této klasifikace se předpokládá, že se objekty s podobnými vlastnostmi budou ve vícerozměrném prostoru shlukovat. V první fázi klasifikace je nutné vytvořit určitý počet shluků a určit polohu centroidu.

Dále se podle zvoleného rozhodovacího pravidla přiřadí jednotlivé pixely příslušným shlukům. Variabilita musí být mezi jednotlivými shluky maximální. Naopak ale variabilita v rámci jednoho shluku musí být co nejmenší. Běžně využívané shlukovací metody jsou K-means a ISODATA.

K-means je algoritmus, ve kterém se definuje požadovaný počet shluků a poloha jejich středů. Všechny pixely jsou následně přiřazeny shluku, k jehož průměrovému vektoru (centroidu) má nejbližší. V následujícím kroku se vypočte nová poloha centroidů a celý proces se opakuje, dokud centroid přestane výrazně měnit polohu, nebo když přestane docházet k významným změnám v počtu řazení pixelů. V metodě ISODATA se nejprve nastaví počet shluků a počet iterací. Následné přiřazení pixelů do shluků se řídí předem určenými pravidly (Dobrovolný, 1998).

3.3 Fotogrammetrie

Fotogrammetrie je vědní obor, který se zabývá měřením rozměrů, rekonstrukcí tvarů a určováním polohy předmětů, které jsou zobrazeny na fotografických snímcích. Fotografický záznam je tvořen buď analogově, nebo digitálně. Pro vytvoření snímků se používají různé druhy zařízení. Každé zařízení má odlišnou přesnost záznamu. Nejdůležitější součástí snímku je určení polohy jednotlivých bodů, které slouží k odvození různých veličin, např.: velikost, tvar, umístění předmětu na snímku, provedení výškopisu a polohopisu, apod. (Pavelka, 2003). UAV fotogrammetrie je označení pro měření, při kterých se používají bezpilotní letecké prostředky různých druhů, které slouží k fotogrammetrickému měření. Velkou výhodou u tohoto snímkování je vertikální pohled s blízkou vzdáleností a možnost vysokého rozlišení u pořízeného snímku. V obou případech (klasické i UAV) fotogrammetrii se vychází z geometricko-matematické rekonstrukce směru fotografických paprsků na snímku. Veškeré principy UAV fotogrammetrie vycházejí z letecké fotogrammetrie, ale vzhledem ke specifickým charakteristikám letových modelů a celé řadě používaných kamer je nutné aspoň částečně upravit klasické postupy zpracování nashromážděných dat (Eisenbeiss, 2009).

Fotogrammetrii je možné rozdělit z různých hledisek, přičemž ty základní jsou: poloha stanoviště, počet a konfigurace vyhodnocovaných snímků a technologický způsob zpracování. Dělení podle polohy stanoviště můžeme dále rozdělit na pozemní a leteckou fotogrammetrii. Při tomto rozdělení v sobě stanoviště zahrnuje bod zemského povrchu, nad kterým je stroj vycentrován (Miřijovský, 2013).

Pozemní fotogrammetrie spočívá v nepohyblivosti stanoviště, které je umístěno na zemi. Při tvorbě snímků tímto způsobem je dostatek času k přesnému zaměření stanoviště a k úpravě prostorové orientace snímku. Nevýhodou může být jednotlivé překrývání předmětů na snímku. Při letecké fotogrammetrii se stanoviště pro tvorbu snímků nachází v prostředku a ten se pohybuje ve vzduchu. Výhodou je větší záběr zájmové plochy a nevýhodou může být obtížnější určení polohy snímku. Pro tyto případy existují matematické metody, které slouží ke zjištění orientace a polohy snímku (Böhm, 2002).

Počet a konfigurace vyhodnocovaných snímků rozděluje fotogrammetrii na jednosnímkovou, která pracuje s jednotlivými parametry zvlášť a je možné určit pouze 2D souřadnice (plocha objektu, výška, obvod, délka) a vícesnímkovou fotogrammetrii, která spočívá ve vytvoření 3D modelu, kdy se snímky překrývají a je možné vytvořit DEM (Miřijovský, 2013). Pro způsob technologického zpracování snímků, což znamená převod souřadnic snímku na souřadnice prostorové, existují analogové, analytické a digitální metody zpracování (Pavelka, 2003).

3.4 Bezpilotní letecké prostředky v DPZ

Aktuální Česká technická norma (ČSN) 310001 definuje bezpilotní letecký prostředek takto: letadlo způsobilé létat bez pilota, které je za letu řízené dálkově ze země nebo automatickým zařízením.

Pro označení bezpilotního leteckého prostředku slouží více pojmů a zkratk: UAV (angl. Unmanned Aerial Vehicle), dron (angl. Drone), UAS (angl. Unmanned Aerial Systems), (Everaerts, 2008), RPA (angl. Remotely Piloted Aircraft) (Icao, 2011). Úřadem pro civilní letectví je pojem bezpilotní letadlo definováno takto: Letadlo určené k používání bez pilota na palubě (ÚCL, 2008).

Rozvoj bezpilotních leteckých prostředků má dlouhou historii. Během druhé poloviny 19. století, konkrétně v roce 1858, se podařilo francouzskému fotografovi G. F. Tournachonovi (známý též jako Nadar) prostřednictvím horkovzdušného balónu pořídit první letecký snímek. Toto období lze považovat za vznik DPZ pomocí bezpilotních leteckých prostředků (Leggat, 1995). Dalšímu velkému vývoji v tomto odvětví vděčíme především vojenskému sektoru, který vynakládá velké finanční prostředky pro rozvoj nových technologií. Díky uvolnění určitých technologií do komerční sféry se počátkem 21. století začali vyrábět a prodávat první bezpilotní prostředky určené pro veřejnost (Karas & Tichý, 2016).

Platformy, které jsou využívány u bezpilotních leteckých prostředků, je možné rozdělit na základě mnoha kritérií. Karas & Tichý (2016) uvádějí hned několik dělení bezpilotních prostředků z hlediska:

- ovládání/řízení: manuální, automatické, kombinované;
- zaměření: běžní uživatelé, pokročilí uživatelé, profesionálové;
- další dělení: počet motorů, dostupná výška a vzdálenost, nosnost, apod.

Nejdůležitějším kritériem je pohon UAV, který může být buď motorový, nebo nemotorový. Dalším významným rozdělením UAV je rozčlenění na základě typu: multikoptéry, křídla a letadla (Miříjovský, 2013).

3.4.1 Multikoptéry

Samotný název prozrazuje, že se jedná o prostředek poháněný vrtulemi obdobně jako u vrtulníku. Multikoptéry používají podobný systém, jako vrtulníky, avšak k vyrovnávání kolem vlastní osy nepotřebují zadní kompenzační vrtuli (Miříjovský, 2013). Multikoptéry lze rozdělit podle počtu vrtulí: se čtyřmi (kvadrokoptéra), sešti (hexakoptéra) (Obrázek 4) nebo osmi (oktokoptéra). Tyto vrtule s motory koptrů jsou uloženy proti sobě. Obecně platí pravidlo, čím více vrtulí, tím vyšší bezpečnost při případném poškození vrtule či jednoho motoru, silnější výkon a vyšší stabilita. Mezi kladné vlastnosti multikoptér řadíme: kolmý vzlet, ke kterému není nutný velký prostor a umožňuje ho téměř kdekoliv. Tento prostor je potřebný i k přistání. Možnost použití automatického (podle předem naplánovaného letového plánu) nebo manuálního způsobu létání. Díky své jednoduché

konstrukci je možné lehce měnit snímací senzory (Karas & Tichý, 2016). Mezi záporné vlastnosti multikoptér můžeme zařadit krátkou dobu letu (oproti křídům), která je způsobena větší hmotností a náročnějším pohybem ve vzduchu. Další nevýhodou multikoptér jsou aerodynamické vlastnosti (UAV guide, 2014). Díky univerzálním vlastnostem jsou multikoptéry ideálním prostředkem pro monitoring a snímání lesních ekosystémů.



Obrázek 4: Hexakoptéra Robodrone Kingfisher – pohled shora.

3.4.2 Křídlo

Křídlo (angl. wing), označováno též jako samokřídlo či bezpilotní letoun je specifickým druhem komerčních dronů. Jejich design, konstrukce a využití je inspirováno vojenskými drony (Obrázek 5). Křídla slouží pouze pro mapování území a monitoring. Kvůli konstrukční náročnosti, která většinou nedovoluje měnit snímací senzory (jako je to možné u multikoptér), je využití těchto prostředků omezeno. Křídla mají dvě možnosti vzletu, buď z opalovací rampy, nebo z ruky. Létají automaticky podle letového plánu, který je nutný předem naplánovat a bezdrátově poslat do řídicí jednotky

bezpilotního letadla. Nevýhodou může být způsob přistání, které probíhá většinou automaticky na předem určené místo. Tato pozice by měla být velká nezarostlá lokalita bez překážek. Může ovšem dosahovat až stovky metrů. Hledání ideálních ploch pro přistání je náročné na čas. Výběr nevhodné lokality může mít za následek poškození systému. Záporem může být i vyšší rychlost letu, která může zapříčinit rozostření snímku. U těchto letounů je též možnost přistání do ruky (pilot zajistí bezpečné dosednutí křídla chycením do ruky). Toto přistání je výhodné z hlediska menšího rizika poškození přístroje (vrtule a motoru). Výhodou je doba letu, která se ve většině případech pohybuje kolem 60 minut. Delší doba je způsobena nižší hmotností a letem v jedné letové hladině. Díky této délce může dojít k rozsáhlejšímu monitoringu než u multikoptér. Možnost startu a přistání z ruky, je další výhodou křídla, protože není třeba velké startovací plochy (Karas & Tichý, 2016).



Obrázek 5: SenseFly eBee – pohled shora.

3.4.3 Legislativní opatření

V České republice je provoz UAV řízen platnými legislativními nástroji. Prvním je zákon č. 49/1997 Sb., o civilním letectví a druhý je zákon č. 455/1991 Sb., o živnostenském podnikání (živnostenský zákon), ve znění pozdějších předpisů. Ministerstvo dopravy vydalo letecký předpis L 2 Pravidla létání, jehož nedílnou součástí je Doplněk X, který reguluje pravidla pro využívání bezpilotních letadel. Je zde stanovena maximální vzletová hmotnost a účel použití.

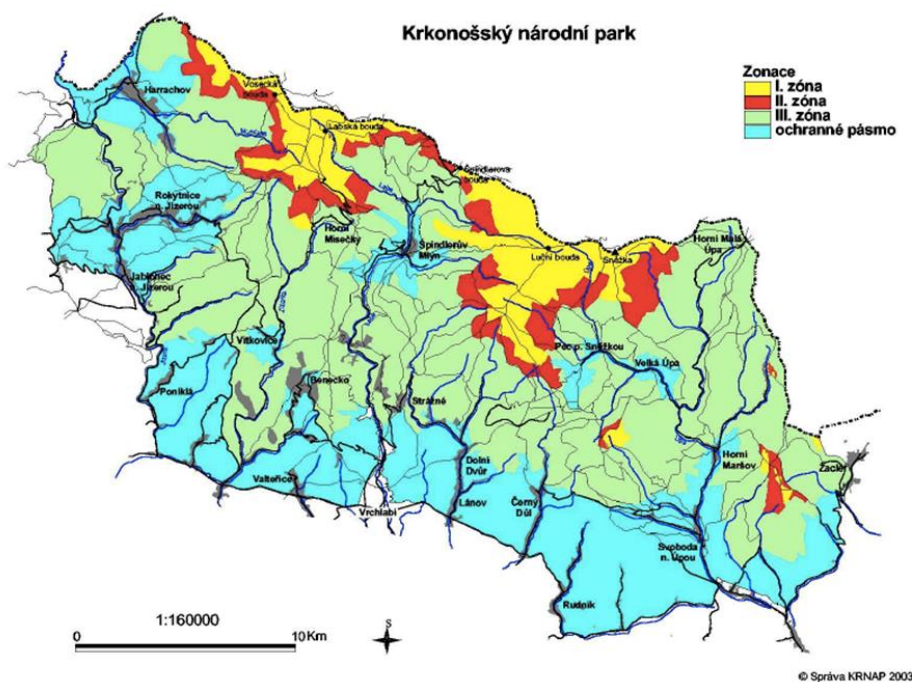
Dalším omezením pro používání UAV je zákon č. 114/1992 sb. o ochraně přírody a krajiny. Konkrétně v §16 zakazuje: létat v rozporu s podmínkami stanovenými v opatření obecné povahy vydaném podle jiného právního předpisu, kromě letů pro zajištění bezpečnosti státu, ochrany osob, majetku nebo veřejného pořádku, a letů pro potřeby orgánů ochrany přírody. Na základě těchto legislativních omezení bylo nezbytné požádat odbor státní správy o povolení k provádění monitoringu UAV na území Krkonošského národního parku.

3.5 Krkonošský národní park

Krkonoše jsou nejvyšším pohořím Česka a České vysočiny. Leží v severovýchodních Čechách a jsou významnou přírodní a historickou oblastí. Na rozloze 36 327 ha zde byl v roce 1963 vyhlášen Krkonošský národní park (Tabulka 1). Později k této rozloze bylo přidáno tzv. ochranné pásmo o rozloze 18 642 ha. Celková plocha lesů se rozkládá na 67 % z výměry KRNAP (Schwarz, 1997). Severní hranice parku je vedena po státní hranici s Polskem, kde národní park Karkonoski Park Narodowy vznikl již v roce 1959 na ploše 5 560 ha. V roce 1992 byly Krkonoše zařazeny do Bilaterální biosférické rezervace, kterou vyhlásila Organizace spojených národů pro vzdělávání, vědu a kulturu (Flousek 1994, Schwarz 2010). Nadmořská výška národního parku se pohybuje v rozmezí od 400 m. n. m. do 1602 m n. m. a celé území je rozděleno na tři zóny s rozdílným ochranným režimem viz Obrázek 6.

Do zóny I. jsou zařazeny území s nejvyšší přírodovědnou hodnotou s výskytem unikátních ekosystémů krkonošské akro-alpínské tundry, které se nacházejí v nejvyšších částech pohoří. Tyto ekosystémy byly v minulosti jen relativně málo ovlivněny lidskou

činností. Cílem jejich ochrany je zachovat či obnovit samořídící funkce a zamezit lidským zásahům do přírodních procesů. Ochrana přírody je zde nejpřísnější. Zónu II. tvoří území s významnými přírodními hodnotami, kdy lesní i zemědělské ekosystémy byly pozměněny šetrnou a přírodě blízkou lidskou činností. Cílem je udržení přírodní rovnováhy, podpora druhové rozmanitosti a navrácení ekosystémů do přirozeného stavu. Prostorové propojení se zónou I. však značně ovlivňuje zdejší druhovou diverzitu. Do zóny III. patří zemědělské i lesní ekosystémy, které jsou značně pozměněny lidskou činností a hospodařením. Do této zóny patří i nevelké sídelní útvary (malé obce a vesnice). Cílem je podpora ekologické formy zemědělského a lesního hospodaření a udržení místa pro rekreaci, turistiku a bydlení (Schwarz, 2010).



Obrázek 6: Geografické vymezení zájmového území se znázorněním zonace. Dostupné z: <http://geografie.kvalitne.cz/ochrana/krn timer>

Tabulka 1: Výměry jednotlivých zón v KRNAP (Schwarz, 2010).

Území	Výměra (ha)
Zóna I.	4 503
Zóna II.	3 416
Zóna III.	28 408
Ochranné pásmo	18 642
Celková výměra KRNAP	54 969

3.5.1 Lesní hospodářství na území KRNAP

Hospodaření v Krkonoších se řídí Plánem péče pro Krkonošský národní park a jeho ochranné pásmo z roku 2010 a je platný až do roku 2020. Protože je celé území tvořeno lesy národního parku a jeho ochranným pásmem, je nutné při jakémkoliv zásahu do lesních ekosystémů dodržovat řadu požadavků ochrany přírody (Schwarz, 1997). Konkrétně se jedná o rozdílný ekosystémový přístup k lesu podle souboru lesních typů (SLT), stupně přirozenosti lesních porostů a zóny odstupňované ochrany přírody (Vacek, 2010). Lesní porosty v Krkonošském národním parku jsou v plánu péče a v platném lesním hospodářském plánu (LHP) rozřazeny do pěti stupňů přirozenosti (A – les původní; B – les přírodní; C – les přírodě blízký; D – les kulturní; E – les nepůvodní). Toto rozdělení lesů udává rozdíl mezi aktuální a přirozenou strukturou (druhová, věková a prostorová) lesního porostu, které je dané mírou ovlivnění lidskými zásahy. Pro hodnocení stupně přirozenosti je zásadní, zda byl v lesním porostu proveden zásah člověka a do jaké míry je tímto zásahem ovlivněna struktura či dynamika vývoje (Schwarz, 2010).

3.6 Lýkožrout smrkový

Lýkožrout smrkový (*Ips typographus* (Linnaeus, 1758)) se řadí mezi nejvýznamnější hospodářské škůdce kulturních porostů s větším podílem smrků v Evropě a Asii, především díky své schopnosti se exponenciálně množit v příhodných klimatických a potravních podmínkách. Lýkožrout smrkový napadá zejména stromy oslabené, jejichž schopnost čelit náletu brouků je snižena, popřípadě stromy, které jsou poškozené kalamitou, vývraty a zlomy, protože už nemusejí překonávat obranné reakce stromů. Pozdní zpracování a odstranění následků kalamit ve spojení se slunečným, teplým počasím

a suchem představují ideální podmínky pro kůrovcové přemnožení, během kterého jsou brouci schopni napadnout i stromy zdravé. To má za následek odumření nejen jednotlivých stromů, ale i rozsáhlé komplexy smrkových porostů (Kindlmann, 2012).


3.6.1 Popis a taxonomické zařazení

Lýkožrout smrkový je brouk, který ve své dospělosti dorůstá do velikosti 4,2 až 5,5 mm a šířky 1,9 mm. Jeho tělo je válcovitého tvaru. Barvu po vylíhnutí z vajíčka má bílou, poté žlutou a postupně tmavne do tmavohnědé až černohnědé barvy. Jeho tělo je lesklé až na zkosenou zadní část krovek, která je matná. Povrch těla lýkožrouta smrkového je pokrytý drobnými světležlutými chloupky. V zadní části krovek má čtyři zuby, přičemž třetí pár shora je největší. Pohlavní dimorfismus není výrazný, samička má pod ústním ústrojím rýhy, samci mají výrazně zvětšený třetí zub v zadní části krovek (Kula, 2014). Lýkožrout smrkový patří do řádu *Coleoptera* (brouci) čeledi *Curculionidae* (nosatcovití), podčeleď *Scolytinae* (kůrovcovití) a rodu *Ips*, kam byl zařazen v roce 1894 Reitterem. Pfeffer (1995) uvádí, že podčeleď kůrovcovití (*Scolytinae*) osahuje více než 5000 druhů. Potravně vázáno k rodu *Picea* je 56 druhů, z toho 39 druhů napadá konkrétně smrk ztepilý (*Picea abies*). Jelínek (1993) zaznamenal 111 druhů kůrovců v České republice, z toho 31 zástupců bylo na smrku ztepilém (Pfeffer, 1995). Výskyt lýkožrouta smrkového závisí především na přirozeném areálu jeho živných dřevin (*Picea*, *Pinus*, *Abies*). Hlavní hostitelskou dřevinou je smrk ztepilý (*Picea abies*), ale může se vyskytovat také na dalších jehličnanech, především na modříněch (*Larix spp.*), zřídka na jedlích (*Abies spp.*) a vzácně také na borovicích (*Pinus spp.*).

3.6.2 Vývojový cyklus, bionomie

Lýkožrout smrkový může mít v podmínkách střední Evropy ve vyšších polohách (nad 800 m n. m.) jednu generaci a v nižších polohách v závislosti na počasí dvě až tři generace. Jarní rojení začíná v polovině dubna a trvá 10 – 20 dní, letní rojení se objevuje v druhé polovině června (Křístek & Urban, 2013). Nejlepší prostředí kůrovec nalézá vzhledem ke své velikosti pod kůrou 60 - 100 letých stromů, protože mají již dostatečně silnou vrstvu lýka. Rozšiřuje se po celém kmeni nahoru i dolů od hranice suchých a zelených větví pod korunou stromu. Na stromy nalétávají první samci, kteří vytvoří snubní komůrku, kde po 2 - 3 dnech začnou vylučovat agregační feromony

k nalákání dalších samců (snížení obranyschopnosti stromů) a samic (účel páření). Na místech závrtů jsou vidět během napadení hnědé drtinky, později jsou napadené stromy identifikovatelné díky výronu pryskyřice.



Obrázek 7: Bionomie lýkožrouta smrkového (Novák et al., 1974).

Jedná se o polygammí druh, tudíž se každý samec páří se dvěma až pěti samicemi, které následně vyhloubí matečné chodby dlouhé 10 – 12 cm kolmé na osu kmenu, v nichž postupně do zářezů kladou 30 – 60 vajíček ve vzdálenosti 1 – 10 mm. Samička naklade jedno až dvě vajíčka za den, v průběhu života celkem mezi 20 až 100 vajíčky (Křístek & Urban, 2013). Část samic zakládá tzv. sesterské rojení, což je kladení vajíček bez další kopulace asi 2 – 3 týdny po první rojení na stejném nebo dalším hostitelském stromě v okolí. Z vajíček se po dvou týdnech líhnou larvy, které procházejí třemi instary. Délka jejich vývoje je značně variabilní v závislosti na počasí, kvalitě potravy, parazitaci a trvá 7- 50 dní. Larvy vytváří larvální chodby, na jejichž konci vytvoří rozšířený prostor (tzv. kukelnou kolébku) a zde se zakuklí. Po 1 – 2 týdnech se z kukel líhnou nedospělý jedinci (žlutí brouci), kteří musí projít úživným žírem, aby došlo k dokončení vývoje létacího svalstva (Obrázek 7). Dospělí brouci poté opouští požerky výletovými otvory a

zakládají dceřinou generaci. Celkový vývin od vajíčka po dospělého jedince trvá v závislosti na počasí šest až deset týdnů. Lýkožrout smrkový je schopný přezimovat ve stádiu larvy až dospělého pod kůrou napadených stromů, dospělý jedinec poté i v hrabance (Kula, 2014).

3.7 Přehled současného stavu řešení

Autorů, kteří se zabývají včasnou detekcí stromů napadených lýkožroutem smrkovým, je hned několik. Abdullah et al. (2018) ve své práci řeší tzv. "zelený útok", což je období, kdy jsou stromy již napadeny kůrovcem a vyvíjí se pod jeho kůrou, ale nevykazují žádné vizuální příznaky napadení nebo stresu. Očekává se, že při zeleném útoku je ovlivněn fyziologický a chemický stav stromů. Konkrétně se mění biochemické vlastnosti asimilačního aparátu, tedy obsah chlorofylu a dusíku v jehlicích, s touto změnou se následně mění i spektrální odrazivost, která byla měřena v rozsahu 400 – 2000 nm. Významné statistické rozdíly byly zjištěny ve středních odrazových spektrech (NIR, SWIR mezi 730 a 1370 nm). Studie prokazuje změny obsahu biochemických látek v listech, tedy změnu spektrální odrazivosti listů u počáteční fáze napadení a lze tedy úspěšně tuto metodu využít k včasné detekci stromů napadeným kůrovcem.

Další studie zabývající se mapováním porostů poškozených kůrovcem pomocí UAV nesoucí RGB a hyperspektrální kamery publikoval Näsä et al. (2015). Ten mapoval finské lesy, na kterých v horní etáži dominoval z 95 % smrk ztepilý (*Picea abies*) a byly již od roku 2010 poškozovány kůrovcem. Ke snímání využil hyperspektrální snímač, který identifikoval dospělé napadené smrky a díky bodovému rozlišení snímků s přesností 74,7 % pro jednotlivý strom. Výsledkem bylo vytvoření a zařazení stromů do klasifikačních tříd (mrtvý, napadený a zdravý) strom s přesností 90 %. Autoři předpokládají, že tato snímací technologie bude mít v budoucnu velké využití pro identifikaci poškození stromů a následné zkoumání spektrálních charakteristik od počáteční fáze napadení až po smrt stromu. Minařík & Langhammer (2016) prováděli studii, která byla zaměřená na využití potenciálu multispektrálních snímků s ultra vysokým rozlišením pro analýzu stavu smrkových porostů. Lokalitou byla Šumava (hranice mezi ČR a Německem), kde po bouřích a vichřicích došlo k masivnímu útoku lýkožrouta smrkového, což přispělo k rozsáhlému narušení a následnému rozpadu porostů. Jelikož se oblast nachází v národním

parku Šumava, porosty jsou zde ponechány samovolnému vývoji. K nasnímání byl použit UAV s multispektrální kamerou, kde spektrální pásma senzoru pokryly odrazivost v červené, zelené a blízké infračervené oblasti. Ze získaných snímků byly vypočítány vybrané spektrální indexy, které dokázaly správně rozlišit hraniční kategorie zastupující zdravé a mrtvé stromy. Dále bylo prokázáno, že index NDVI má vyšší diferenci v zónách zdravého nebo mírně poškozeného lesa, zatímco index SR vykazuje vyšší citlivost pouze v zónách poškozeného lesního porostu. Index GNDVI nedokázal odlišit jednotlivé stromy a ani další stupně poškození porostů. Studie prokazuje využitelnost UAV s multispektrálními senzory pro analýzy poškození lesních porostů. Poškozením porostů ve Vysokých Tatrách v době kůrovcové kalamity se zabýval Mezei et al. (2014). Studie zkoumá závislost faktorů ovlivňující vývoj kůrovcové kalamity (vliv větru, staří a stav porostů, radiace, lokalita apod.) a dopad těchto faktorů na úmrtnost lesních porostů. V první fázi vývoje kalamity nejvíce úmrtnost stromů ovlivňovaly faktory větru, stav porostů a stáří, naopak ve fázi, kdy kalamita gradovala, téměř veškerou úmrtnost způsobili kůrovci.

Potenciál využití indexu NDVI z UAV dat pro sledování zdravotního stavu porostů ve své práci popisuje Stoyanova et al. (2018). V této studii mapují rozsáhlé a těžce dostupné lesy v Bulharsku napadené lýkožroutem smrkovým, kde pomocí NDVI indexu rozlišují zdravé a napadené stromy. Hodnoty indexu NDVI v rozmezí 0,45 – 0,5 značily poškozené oblasti porostu a hodnoty indexu NDVI 0,7 – 0,95 značily nenapadené oblasti porostu. Autoři zmiňují, že včasná identifikace postižených lesních ploch je prvním důležitým krokem k řešení problému. Mohou se provést preventivní opatření dříve, než jsou stromy zničeny a napadení porostů je již viditelné. Pořizování a používání snímků multispektrální kamerou může být velkým přínosem a tato studie to prokazuje.

4. Metodika

4.1 Zájmové území

Lokalita zvolená pro monitoring lýkožrouta smrkového se nachází na území Krkonošského národního parku. Sledované porosty se vyskytují v lesnickém úseku Obří důl, spadajícího pod územní pracoviště Pec pod Sněžkou, lesní hospodářský celek: Horní Maršov. Obří důl je jednou z nejcennějších lokalit Krkonoš. Pro sledování vývoje napadení porostu kůrovcem byly vybrány lesy, kde byl předpoklad výskytu brouka již v minulých letech. Porost se rozkládá v I. zóně KRNAP a jedná se o území v bezzásahovém režimu ponechaný samovolnému vývoji. Vzhledem k tomuto faktu se zde neuskutečňují žádné zásahy proti kůrovcům ani jiným biotickým či abiotickým škodlivým činitelům a jsou vhodné pro monitoring všech stádií vývoje lýkožrouta smrkového. Vzniká zde možnost sledovat všechna vývojová stadia kůrovce, od jeho náletu na zdravý strom, přes založení nové generace až po dokončení celého vývoje a následné rojení nového pokolení.

Letecký monitoring sledované lokality pomocí UAV se konal v pravidelných časových intervalech v období po jarním rojení kůrovce, tedy od začátku června 2017 do začátku října 2017 (Tabulka 2). Dodržení časového intervalu bylo nutné pro následné porovnání a statistické zpracování leteckých snímků, které by případně mohly prokazovat rozdíly mezi napadenými a zdravými stromy. Letová hladina a průběh automatizovaného letu byl proveden tak, aby vznikl dostatečný překryv pro další počítačové úpravy vzniklých snímků.

Tabulka 2: Označení období náletů s přesnými daty průběhu náletu.

Období	Datum náletu
A	15. 6. 2017
B	1. 8. 2017
C	30. 8. 2017
D	1. 10. 2017

4.2 Použité UAV pro monitoring zájmového území

Ke sledování napadeného lesního porostu byl využit bezpilotní systém Zefyros Oktos XL (Obrázek 8). Jedná se o multikoptéru, konkrétně je to oktokoptéra s osmi elektromotory, jež jsou připevněny na ramenech ve shodných vzdálenostech od středu. Ke snímání byla použita kamera Lumix TZ7, opatřena upraveným snímačem s rozlišením 10MPx a CCD senzorem snímajícím v NIR části spektra. Druhým snímacím zařízením byl fotoaparát Sony Alpha A7, který má rozlišení 24 Mpx a je opatřený CMOS senzorem. Snímky pořizuje ve viditelné části spektra (RGB).




Obrázek 8: Zefyros Oktos XL – pohled shora.

4.3 Zpracování dat

Díličí snímky, které vznikly při leteckém monitoringu UAV, byly spojeny do souvislé scény v programu Agisoft Photoscan. Následně v programu ESRI ArcGIS pomocí funkce Composite Bands došlo ke spojení rastrů jednotlivých barevných kanálů a vznikla tak časová řada čtyř snímků, které obsahují informace o barevných kanálech RGB a NIR. Obrazy ve formátu TIFF byly následně použity jako podklady pro segmentaci a klasifikaci.

Software eCognition je nástrojem pro klasifikaci „per-object“ – objektivě orientovaná analýza obrazu. Ta umožňuje zahrnout do postupu zpracování i kontextuální informace. Celý proces objektivě orientované analýzy obrazu sestává ze segmentace obrazu a následné klasifikace na základě charakteristik jednotlivých segmentů. Specifikem objektivě orientované analýzy obrazu je, že základní jednotkou pro klasifikaci není pouze obrázkový prvek (pixel), ale celá skupina prostorově spolu souvisejících pixelů - objekty nebo též segmenty. V procesu vytvoření segmentace (v případě této studie byl zvolen Multiresolution Segmentation algoritmus) je celý obraz rozčleněn dle zadaných parametrů do jednotlivých nepřekrývajících se homogenních objektů. Základními parametry pro vytvoření segmentace je Scale parametr (velikost segmentů musí odpovídat požadavkům dalšího zpracování), Shape Factor (faktor tvaru) a Compactness (faktor kompaktnosti). Hledání vhodných parametrů pro segmentaci do značné míry závisí na empirii. Bylo nutné měnit a zkoušet různé nastavení těchto parametrů, než byly nalezeny hodnoty vstupních parametrů, kdy jeden segment byl jako jedna koruna stromu. K nejlepším výsledkům segmentace obrazu v této práci došlo při nastavení Scale parametru o hodnotě 200, Shape Factor 0,4 a Compactness 0,5. Toto nastavení parametrů se jeví jako nejlepším pro vzniklé segmenty, protože byly zachovány tvary a hranice mezi jednotlivými objekty na snímku (Obrázek 9).



Obrázek 9: Segmentace sledované lokality; rozdělení validačních dat; výsledná klasifikace.

Pro obě klasifikace – klasifikace NN a klasifikace Decision Tree, v této práci byla zvolena řízená klasifikace, stejné segmenty a validační data. V prvním případě byl použit klasifikátor Nearest Neighbour - NN. Ten posuzuje příslušnost daného pixelu k určité třídě nejen na základě jeho vzdálenosti od středu shluku, ale také na základě aritmetického


zastoupení pixelů konkrétní třídy v okolí zpracovaného obrazového prvku. Algoritmus vyhledá klasifikovanému pixelu předem stanovený počet (K) nejbližších pixelů, bez ohledu na trénovací množiny. Pixel je poté přiřazen do třídy, která v množině K sousedů převažuje (Dobrovolný, 1998).

Celé klasifikaci předchází důležité nadefinování tříd (Class Hierarchy), do kterých jsou jednotlivé segmenty zařazeny. Pro účely této klasifikace byly vytvořeny celkem tři informační třídy – zdravý, napadený a mrtvý strom. Dalším krokem je tzv. trénovací fáze, ve které byly zvoleny kalibrační (trénovací) a validační data, ty slouží jako základ pro celou klasifikaci (Obrázek 10). Tato data byla vybrány náhodným způsobem v poměru viz Tabulka 3. Klasifikační charakteristiky pro NN byly Mean (průměr) a Standard Deviation (směrodatná odchylka) pro všechny vstupní vrstvy. Následně byl proveden výběr tříd (zdravé, mrtvé, napadené stromy) pro které se má klasifikace provést a spuštění celé klasifikace. Vyhodnocení celé klasifikace je k nalezení v Accuracy Assessment (posouzení přesnosti) v podobě Error Matrix - chybové (konfusní) matice.

Tabulka 3: Poměr náhodně vybraných trénovacích a validačních dat

	Zdravý strom	Napadený strom	Mrtvý strom
Trénovací data:	100	11	40
Validační data:	78	15	40

Pro druhou klasifikaci byl zvolen tzv. Classification Tree (Decision Tree). Při tvorbě Decision Tree se postupuje metodou Divide and Conquer („rozděl a panuj“), při které jsou trénovací data postupně rozdělena na menší podmnožiny (uzly stromu), tak aby v těchto podmnožinách převládaly příklady jedné třídy. Lze tedy říct, že na počátku je jedna množina trénovacích dat a na konci jsou podmnožiny tvořené příklady téže třídy (Quinlan, 1979). Tento postup byl zvolen na základě předpokladu změn spektrální odrazivosti napadených stromů v jednotlivých spektrálních pásmech za určitý čas. Pro tuto klasifikaci bylo nutné vytvořit vlastní klasifikační podmínku pro zařazení napadených stromů do tříd: $NIR\ 1 > NIR\ 2$ and $RED\ 1 < RED\ 2$, přičemž tento předpoklad vychází z metodiky pro detekci napadených stromů (Klouček at al., 2019).



Obrázek 10: Segmentace sledované lokality; rozložení tzv. Ground Truth dat v prostoru a jejich náhodné rozdělení do skupin kalibrační/validační; zelené značí zdravé stromy, žluté stromy napadené a červené stromy mrtvé.

Ten spočívá v odhalení stromů, u kterých došlo k nárůstu odrazivosti v červené (RED) části spektra a zároveň v poklesu odrazivosti v blízkém infračerveném spektru (NIR). Pro zajištění této podmínky je nutné mít snímky alespoň ze dvou různých období. Dílčím cílem této práce je otestovat tuto podmínku, s využitím jiného segmentačního a klasifikačního algoritmu pomocí odlišného softwaru. Pro následné rozdělení zbylých segmentů byl využit index NDVI a podmínka pro jeho výpočet: $[(NIR) - (RED) / (NIR) + (RED)]$. Pro klasifikační charakteristiku byl zvolen pouze Mean (průměr) NDVI v daném segmentu a i u této klasifikace je vyhodnocení pomocí Error Matrix - chybové (konfusní) matice.

4.3.1 Hodnocení přesnosti klasifikace

Jedním z nejvíce používaných přístupů k hodnocení úspěšnosti a ke stanovení vlastností klasifikace je výpočet klasifikační chybové matice. Ta porovnává u všech informačních tříd vztah mezi validačními daty a výsledky klasifikace. Počet sloupců a řádků odpovídá počtu všech klasifikovaných tříd. Ve sloupcích obsahuje skutečnou hodnotu (validační data) předpovídajícího znaku a v řádcích předpověď klasifikátoru (výsledky klasifikace). K hodnocení přesnosti klasifikace na základě chybové matice lze využít několik charakteristik. Prvním z nich je Overall Accuracy (celková přesnost), která udává podíl celkového počtu řádně klasifikovaných segmentů na celkovém počtu segmentů validačních dat bez ohledu na třídu. Dalším hlediskem je User's Accuracy (přesnost uživatele) a vyjadřuje počet správně klasifikovaných pixelů dělený celkovým počtem pixelů, které do této kategorie byly zařazeny. Tento ukazatel tedy vyjadřuje pravděpodobnost, s jakou segment zařazený do dané třídy tuto třídu reálně reprezentuje. Producer's Accuracy (přesnost z hlediska zpracovatele) označuje poměr mezi počtem správně klasifikovaných pixelů a počtem pixelů použitých pro testování dané třídy. Ke kvantitativnímu vyjádření přesnosti výsledků klasifikace je možné použít tzv. Kappa koeficient, který porovnává výslednou klasifikaci s klasifikací vzniklou čistě náhodným procesem zařazování segmentů do tříd. Výpočet tohoto koeficientu je založen na předpokladu, že i při čistě náhodném procesu zařazování jednotlivých pixelů zpracovaného obrazu do jednotlivých tříd bude určité procento těchto pixelů zařazeno správně (např. hodnota koeficientu 0,9 znamená, že jsme se vyhnuly 90 % chyb, které vznikly při náhodném zařazení) (Dobrovolný, 1998).

5. Výsledky

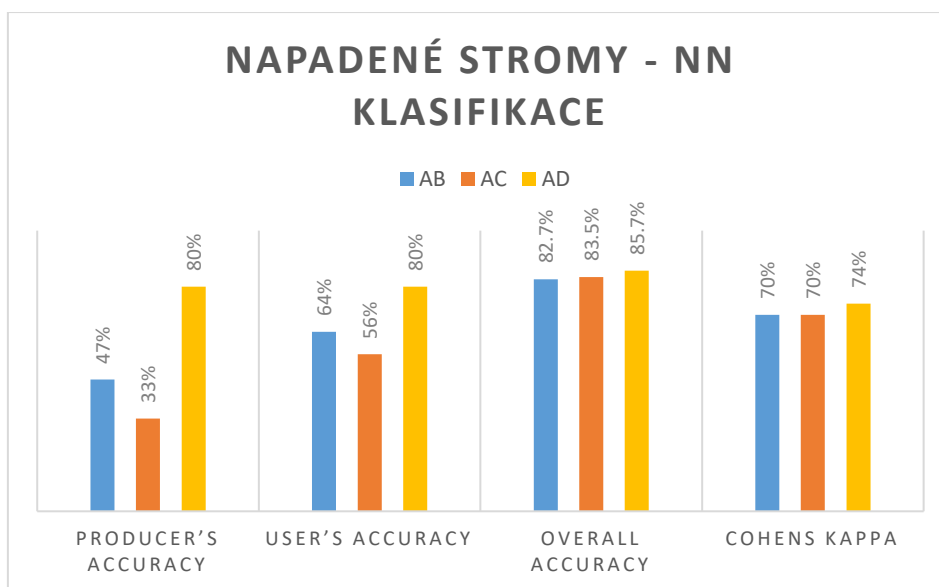
Výsledky studie klasifikace obrazových dat pro účely detekce stromů napadených lýkožroutem smrkovým byly zpracovány pomocí deskriptivní (popisné) statistiky v podobě chybových matic. Klasifikace pro data ze všech sledovaných období dohromady při použití řízeného klasifikačního algoritmu NN ukazuje, že tato klasifikace je možná a vychází s velice dobrými výsledky. Producer's Accuracy pro napadené stromy 80 % a User's Accuracy 86 %. Celková přesnost je velice vysoká 90,2 % a Cohen's Kappa koeficient je 0,82 (Tabulka 4). Podrobné výsledky celé řízené klasifikace NN pro jednotlivé třídy a období jsou v Příloze 1.

Tabulka 4: Přehled výsledků validačních dat pro všechny čtyři sledované období dohromady.

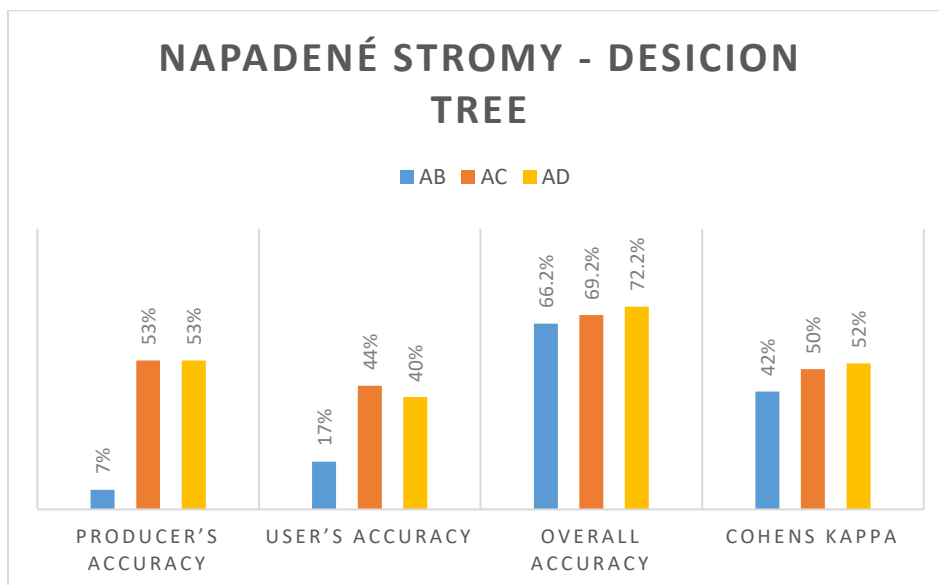
User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	12	2	0	14
zdravé	3	72	4	79
mrtvé	0	4	36	40
sum	15	78	40	133
Producer's Accuracy:	80 %	92.3 %	90 %	
User's Accuracy:	86 %	91.1 %	90 %	
Overall Accuracy:				90.2 %
Cohens Kappa:				0.82

Řízená klasifikace pro dvě různá období pomocí NN klasifikátoru vykazuje celkovou přesnost od 82 % do 85 % (viz Graf 1). Tato klasifikace byla prováděna kumulativně vždy pro dvě sledovaná období dohromady. Nejlepší výsledky z této klasifikace vykazuje období AD – tedy kombinace dat z prvního a posledního náletu. Producer's a User's Accuracy je pro tyto období 80 %, koeficient Cohen's Kappa 0,74. Tyto dva sběry dat mají mezi sebou největší časový rozestup. Konkrétní tabulka s výsledky pro období AD je k nalezení v přílohách. Další dvě klasifikace mají výsledky značně podobné – období AB, tedy kombinace dat prvního a druhého náletu Producer's Accuracy 47 %, User's Accuracy 64 % a období AC, tedy kombinace dat prvního náletu a třetího náletu Producer's Accuracy 33 % User's Accuracy 56 %. Koeficient Cohen's Kappa

je pro obě časové řady stejný 0,7. Podrobné výsledky všech tříd a sledovaných období pro řízenou klasifikaci NN jsou v Příloze 2.



Obrázek 11: Výsledky NN klasifikace napadených stromů pro dvě konkrétní období dohromady.



Obrázek 12: Výsledky Decision Tree klasifikace napadených stromů pro dvě konkrétní období dohromady.

V grafu 2 jsou znázorněny zajímavé charakteristiky pro klasifikaci pomocí Decision Tree. Výsledky pro data z prvního a druhého náletu (AB) řízené klasifikace pomocí Decision Tree jsou v této klasifikaci nejslabší. Ačkoliv je celková přesnost pro tyto dvě období 66,2 %, Producer's Accuracy je pouze 7 % a User's Accuracy je 17 %. Koeficient Cohen's Kappa je 0,42. V dalších dvou sledovaných obdobích je zaznamenán lehký vzrůstající trend. Celková přesnost klasifikace je okolo 70 % a koeficient Cohen's Kappa kolem 0,5. Pro kombinaci dat z prvního a třetího období (AC) je Producer's Accuracy 53 % a User's Accuracy 44 %. Data pro první a poslední období (AD) má hodnoty Producer's Accuracy stejné jako období AC, tedy 53 % a User's Accuracy 40 %. Podrobné výsledky celé řízené klasifikace Decision Tree pro jednotlivé třídy a období jsou k nalezení v Příloze 3. Kompletní výsledky všech klasifikací pro jednotlivé třídy jsou v přílohách v podobě chybových matic.

6. Diskuze

Tato studie se zabývá možností využití snímků UAV při včasné detekci napadených stromů lýkožroutem smrkovým na území Krkonošského národního parku v oblasti Pece pod Sněžkou a následným ověřením kvality použitých klasifikačních algoritmů. Výsledky poukazují na možnost využití DPZ a obrazových dat z UAV v oblasti viditelného a infračerveného pásma elektromagnetického spektra k monitoringu stromů napadených lýkožroutem smrkovým a následné klasifikaci snímků porostu. Brovkina et al. (2018) ve své práci pomocí UAV sledovali zdravotní stav porostů, konkrétně smrku ztepilého a porovnávali UAV snímky ve viditelném a blízkém infračerveném pásmu s odběry vzorků z terénu. V této práci využili objektově orientovanou analýzu obrazu a program eCognition pro rozlišení jednotlivých druhů stromů, a pro určení zdravotních stavů smrků. Výsledná přesnost mé první klasifikace při použití NN klasifikačního algoritmu pro všechna sledovaná období je srovnatelná s jejich výslednou klasifikací pro jednotlivé dřeviny. V jejich případě je koeficient Cohen's Kappa 0,74 a celková přesnost klasifikace 80 %. V případě této práce je celková přesnost klasifikace 90,2 % a koeficient Cohen's Kappa 0,82.

Dalšími autory studie o mapování porostů napadených lýkožroutem smrkovým pomocí UAV a následné klasifikace jsou Nási et al. (2015). Ti ve své práci použili NN algoritmus pro klasifikaci stromů (zdravý, napadený a mrtvý). Výsledky jejich práce poukazují na vysokou přesnost celkové klasifikace kategorie mrtvý strom, která je 90 % a koeficient Cohen's Kappa 0,8. Nižší přesnost následuje v celkové klasifikaci napadených a zdravých stromů, která je 76 % a koeficient Cohen's Kappa 0,6. V této práci při použití NN klasifikátoru dochází k nejlepším výsledkům u kategorie zdravý strom s přesností 90 %, poté je kategorie mrtvý strom s přesností 80 % a kategorie napadený strom s přesností 60 %. Výsledky pro kategorii napadený strom jsou nejméně přesné z důvodu nízkého počtu vstupních dat, které slouží jako trénovací vzorek pro třídu napadený strom (celkem 23). Tuto skutečnost ve své práci zmiňuje i Nási et al. (2015) pro třídu napadený a zdravý strom. Minařík & Langhammer (2016) jsou dalšími autory, kteří ve své studii dokazují schopnost pomocí NDVI indexu určit různé kategorie úpadku stromu (mrtvé, napadené a zdravé) při použití multispektrální UAV kamery zejména v oblasti blízkého infračerveného spektra v lesním porostu napadeným lýkožroutem smrkovým. I v této práci

byl použit index NDVI pro určení kategorie mrtvý a zdravý strom, avšak výsledky nebyly tolik přesné, protože byly ovlivněny klasifikačním algoritmem, který byl použit. Obdobně Abdullah et al. (2018) ve své práci řeší tzv. "zelený útok", při kterém stromy nevykazují vizuální příznaky napadení, ale jsou již napadeny kůrovcem. Při srovnání napadených a zdravých stromů v pásmu NIR dospěli k závěru, že počáteční fáze napadení stromů snižuje obsah biochemických látek v listech, což výrazně ovlivňuje spektrální odrazivost listů a lze tedy včas detekovat napadený strom kůrovcem.

6.1 Doporučení pro další využití

Sběr dat pro tuto práci probíhal v bezzásahové oblasti, kde nebylo možné z napadených stromů odebrat vzorky pro určení vývojového stádia kůrovce. Dalším negativním faktorem, který ovlivňuje výsledky této práce je nepravidelný monitoring UAV sledované lokality kvůli nepříznivým klimatickým podmínkám, proto bych doporučila pravidelný a opakovaný monitoring oblasti. Tato nasbíraná data z monitoringu mohou následně sloužit i jako validační vzorky pro jednotlivé kategorie, které jsou využity pro klasifikaci. Faktorem ovlivňující výsledky klasifikace může být i radiometrická korekce dat, zvolený klasifikační algoritmus nebo vybraný software.

V současnosti lze tuto práci využít ke sledování změn zdravotního stavu jednotlivých stromů i celých porostů. Lze ji využít i k mapování kůrovcových ohnisek a může se stát vhodným metodickým pomocníkem pro lesní hospodáře. Je vhodná zvláště v rozsáhlých chráněných územích (národní parky a jejich zóny), kde lze dobře mapovat ohrožené porosty a případný nárůst poškození lesního porostu.

7. Závěr

Cílem této práce bylo testování metod pro detekci napadených stromů lýkožroutem smrkovým za využití obrazových dat pomocí UAV a ověřit přesnost použitých klasifikačních algoritmů, které rozlišují napadený, zdravý a mrtvý strom. Sledovaná oblast byla zvolena v bezzásahovém území KRNAP, kde neprobíhá zásah proti kůrovci a je zde tedy možnost sledovat změny porostu v průběhu celého vývoje lýkožrouta smrkového. Výsledky práce ukázaly, že klasifikace je možná na základě NN i Decision Tree algoritmu, nejlepší variantou pro obě klasifikace je kombinace dat z prvního a posledního náletu. Při použití NN algoritmu jsou výsledky pro celkovou přesnost 85,7 %, Producer's Accuracy a User's Accuracy napadených stromů 80 % a koeficient Cohen's Kappa 0,74. Při použití Decision Tree pro kombinaci prvního a posledního náletu jsou výsledky pro celkovou přesnost 72,2 %, Producer's Accuracy 53 % a User's Accuracy 40 % pro napadené stromy. Koeficient Cohen's Kappa je v tomto případě 0,52. Při použití Decision Tree je celková přesnost nižší, než při použití NN klasifikátoru a to je způsobeno tím, že podmínka pro Decision Tree je zadána uživatelem bez jakékoliv benevolence, zatímco u NN klasifikátoru je podmínka vytvořena programem a výsledné skupiny si tvoří sám. Z tohoto důvodu vycházejí výsledky lépe na radiometricky nekalibrovaných datech. Ty musí být kalibrovány v rámci scény, ale nemusí být v rámci jednotlivých období. Při Decision Tree algoritmu je nutné mít radiometricky kalibrovaná data. Výrazný vliv na výsledky má také temporální rozlišení, tzn. časové rozmezí kdy, došlo k náletu. Když dojde k prodloužení časového intervalu, výsledky vycházejí lépe, než v případě použití kombinace dat z prvního a druhého náletu.

Výsledky práce poukazují na možnost využití snímků pořízených pomocí UAV pro sledování stavu porostů napadených lýkožroutem smrkovým a následné zpracování dat v softwaru eCognition Developer. Zároveň tato práce může sloužit jako metodika pro použití tohoto softwaru ke klasifikaci napadených stromů s využitím dat z UAV. DPZ je jednou z moderních metod, která slouží ke sledování porostů a monitoringu vývoje lýkožrouta smrkového v těžce dostupných nebo bezzásahových oblastech národního parku. Tato metoda má pro lesní hospodářství velký potenciál, protože včasná opatření mohou předejít šíření kůrovce do okolních porostů anebo zabránit případným následkům např. v podobě kůrovcové kalamity.

8. Přehled literatury a použitých zdrojů

ABDULLAH, H., DARVISHZADEH, R., SKIDMORE, A. K., GROEN, T. A., HEURICH, M. (2018): *European spruce bark beetle (Ips typographus, L.) green attack affects foliar reflectance and biochemical properties*. International Journal of Applied Earth Observation and Geoinformation, 64: 199-209.

BÖHM, J. (2002): *Fotogrammetrie učebné texty*. Ostrava: Vysoká škola banská technická univerzita Ostrava Hornicko - geologická fakulta Institut geodézie a dulního měřictví. 16s.

BROVKINA, O., CIENCIALA, E., SUROVÝ, P., JANATA, P. (2018): *Unmanned aerial vehicles (UAV) for assessment of qualitative classification of Norway spruce in temperate forest stands*. Geo-spatial Information Science, 21, 12–20.

CRACKNELL, A. P., HAYES, L. W. B. (1993): *Introduction to Remote Sensing*. Taylor & Francis. London, New York, Philadelphia. 293 s.

DOBROVOLNÝ, P. (1998): *Dálkový průzkum Země. Digitální zpracování obrazu*. Brno: Masarykova Univerzita. 208 s.

EISENBEISS, H. (2009): *UAV photogrammetry*. Institute of Photogrammetry and Remote Sensing. ETH Zürich, Doctoral Thesis.

EVERAERTS, J. (2008): *The use of unmanned aerial vehicles (UAVs) for remote sensing and mapping*. Belgie: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 37: 1187-1192

FLOUSEK, J. (1994): *Plán péče o Krkonošský národní park a jeho ochranné pásmo (2010 -2020)*, Správa KRNAP, Vrchlabí. 60 s.

FLOUSEK, J., HARTMANOVÁ, O., ŠTURSA, J., POTOCKI, J. (2007): *Krkonoše. Příroda, historie, život*. Praha. 864 s. ISBN 978-80-7340-104-7

HALOUNOVÁ, L., PAVELKA, K. (2005): *Dálkový průzkum Země*. Praha: Vydavatelství ČVUT. ISBN 80-01-03124-1.

ICAO. *Unmanned Aircraft Systems (UAS)* 2011. Montréal: ICAO Cir 328. (online).[cit. 2019-15-01]. ISBN 978-92-9231-751-5, dostupné z: <https://www.icao.int/Meetings/UAS/Documents/Circular%20328_en.pdf>

JAKUŠ, R., BLAŽENEC, M., GURTSEV, A., HOLUŠA, J., HROŠŠO, B., KŘENOVA, Z., LONGAUEROVÁ, V., LUKÁŠOVÁ, K., MAJDÁK, A., MEZEI, P., SLIVINSKÝ, J. (2015): *Princípy ochrany dospělých smrekových porastov pred podkôrnym hmyzom*. Ústav ekológie lesa: Slovenská akadémia vied. ISBN 978-80-89408-21-4.

JAKUŠ, R., CUDLÍN, P., SLIVINSKÝ, J., MEZEI, P., MAJDÁK, A., BLAŽENEC, M. (2015): *Hodnotenie zdravotného stavu smreka vo vzťahu k náletu podkôrneho hmyzu a k odumieraniu lesa*. Ústav ekológie lesa: Slovenská akadémia vied. ISBN 978-80-89408-22-1.

KARAS, J., TICHÝ, T. (2016): *Drony*. Brno: Computer press, Albatros Media a. s., 264 s. ISBN 978-80-251-4680-4.

KINDLMANN, P., MATĚJKA, K., DOLEŽAL, P. (2012): *Lesy Šumavy, lýkožrout a ochrana přírody*. Praha: Karolinum. 325 s. ISBN 978-80-246-2155-5.

KLOUČEK, T., KOMÁREK, J., LAGNER, O., FOGLI, M., GDULOVÁ, K. (2019): *Detekce napadení lesních porostů pomocí bezpilotních leteckých prostředků – Certifikovaná metodika*. Praha. 66 s. ISBN 978-80-213-2932-4, in press.

KOLÁŘ, J. (1989): *Dálkový průzkum Země*. SNTL, Praha. 170 s.

Krkonošský národní park. *Geografie kvalitně* (online) [cit. 2019-03-10]. Dostupné z: <<http://geografie.kvalitne.cz/ochrana/krnep.htm>>

KŘÍSTEK J., URBAN J. (2013): *Lesnická entomologie*. Academia, Praha. 445 s., ISBN 978-80-200-2237-0

KULA, E. (2014): *Ochrana lesa ve stredoevropských podmínkách 1. část Lýkožrout smrkový (Ips typographus L.) kalamitní škůdce smrkových ekosystémů střední Evropy*. Skripta, Mendelova univerzita Brno. 69 s.

LEGG, CH.A. (1994): *Remote Sensing and Geographic Information System: Geological mapping, mineral exploration and mapping*. Wiley a Sons. Chister, New York, Brisbane, Toronto, Singapore. 166 s

LEGGAT, R., 1995: *A History of Photography – from its beginnings till the 1920s*. (online). [cit. 2019-16-01], dostupné z: <http://lnx.phototeka.it/documenti/Cenni_storici_fotografia.pdf>

LEHMANN, J. R. K., NIEBERDING, F., PRINZ, T., Knoth, C. (2015): *Analysis of unmanned aerial system-based CIR images in forestry-a new perspective to monitor pest infestation levels*. *Forests*, 6(3), 594–612.

LUKAS, V. (2011): *Mapování variability půdy a porostů v precizním zemědělství: metodika pro praxi*. Mendelova univerzita v Brně. 2011. 34 s., ISBN 978-80-7375-562-1.

MATHER, P., KOCH M. (2011): *Computer Processing Of Remotely-Sensed Images : An Introduction*. Chichester, West Sussex, UK: Wiley.

MEZEI, P., GRODZKI, W., BLAŽENEC, M., JAKUŠ, R. (2014): *Factors influencing the wind – Bark beetles' disturbance system in the course of an Ips typographus outbreak in the Tatra Mountains*. *Forest Ecology and Management*. 312, p. 67–77.

MINAŘÍK, R., LANGHAMMER, J. (2016): *Use of a multispectral UAV photogrammetry for detection and tracking of forest disturbance dynamics*. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 41, s. 711–718.

MÍŘIJOVSKÝ, J. (2013): *Fotogrammetrický přístup při sběru geodat pomocí bezpilotních leteckých zařízení*. Olomouc: Univerzita Palackého v Olomouci. Přírodovědecká fakulta. Disertační práce (Ph.D.). Vedoucí disertační práce Prof. RNDr. Vít Voženílek, CSc.

NÄSI, R., HONKAVAARA, E., LYYKÄINEN-SAARENMAA, P., BLOMQVIST, M., LITKEY, P., HAKALA, T., VILJANEN, N., KANTOLA, T., TANHANPÄÄ, T., HOLOPAINEN, M. (2015): *Using UAV-Based Photogrammetry and Hyperspectral Imaging for Mapping Bark Beetle Damage at Tree- Level*. *Remote Sensing*. 7, 15467-15493.

NOVÁK V., HROZINKA F., STARÝ B., (1974): *Atlas hmyzích škůdců lesních dřevin*. Liberec: SZN, 127s. ISBN 07-007-74

PAVELKA, K. (2003): *Fotogrammetrie 10*. Vyd. 2. přeprac. Praha: Vydavatelství ČVUT, 194 s. ISBN 80-01-02649-3.

PFEFFER, A. (1995): *Zentral - und westpaläarktische Borken und Kernkäfer (Coleoptera: Scolytidae, Platypodidae)*. Basel: Pro Entomologia. 310 s. ISBN 3-9520840-6-9.

QUINLAN, J. R. (1979): *Discovering rules by induction from large collections of examples*. In: (Michie, ed.), *Expert Systems in the Micro-Electronic Age*. Edinburgh University Press.

SCHWARZ, O. (1997): *Rekonstrukce lesních ekosystémů Krkonoš*. Správa KRNAP, Vrchlabí. 174 s. ISBN 80-902489-1-8

SCHWARZ, O. (2010): *Plán péče o Krkonošský národní park a jeho ochranné pásmo (2010 – 2020)*. Správa KRNAP, Vrchlabí. 179 s.

STOYANOVA, M., KANDILAROV, A., KOUTEV, V., NITCHEVA, O. (2018): *Potential of multispectral imaging technology for assessment coniferous forests bitten by a bark beetle in Central Bulgaria*. MATEC Web of Conferences 145, 01005.

SVATOŇOVÁ, H., LAUERMAN, L. (2010): *Dálkový průzkum Země – aktuální zdroj geografických informací*. Brno: Masarykova univerzita. ISBN 978-80-210-5162-1

SVATOŇOVÁ, H., LAUERMAN, L., 2006: *Dálkový průzkum Země z družice* (online). [cit. 2019-22-01], dostupné z <<https://educoland.muni.cz/down-174/>>.

ÚŘAD PRO CIVILNÍ LETECTVÍ, 2008: *Doplňující informace ÚCL k návrhu Doplnku X leteckého předpisu L2*. In: Caa. (online).[cit. 2019-30-01]. Dostupné z: <http://www.caa.cz/file/2250_1_1/>.

VACEK, S., VACEK, Z. SCHWARZ, O. (2010):. *Struktura a vývoj lesních porostů na výzkumných plochách v národních parcích Krkonoš*. Lesnická práce, Kostelec nad Černými lesy. 568 s. ISBN 978-80-87154-41-0

ŽÍŽALA, D., KRÁSA, J., BÁČOVÁ, M., ZELENKOVÁ, K., LABURDA, T., NOVOTNÝ, I. (2016): *Monitoring erozního poškození půd v ČR nástroji dálkového průzkumu Země*. Praha: Výzkumný ústav meliorací a ochrany půdy. ISBN 978-80-87361-63-4.

Zákony a normy:

Česko. ČNR. Zákon České národní rady č. 114 ze dne 19. 2. 1992 o ochraně přírody a krajiny. In Sběrka zákonů České republiky. 1992, částka 28, s. 666–692.

9. Seznam obrázků a tabulek

Obrázek 1: Schéma elektromagnetické vlny (Dobrovolný, 1998).....	14
Obrázek 2: Rozdělení elektromagnetického spektra (Homolová et al., 2014).....	16
Obrázek 3: Schopnost listů odrážet různé formy světla v závislosti na zdravotním stavu dřeviny. Dostupné z: < http://www.innovativegis.com/basis/pfprimer/topic7/topic7.html >	18
Obrázek 4: Hexakoptéra Robodrone Kingfisher – pohled shora.	25
Obrázek 5: SenseFly eBee – pohled shora.	26
Obrázek 6: Geografické vymezení zájmového území se znázorněním zonace. Dostupné z: < http://geografie.kvalitne.cz/ochrana/krnep.htm >	28
Obrázek 7: Bionomie lýkožrouta smrkového (Novák et al., 1974).....	31
Obrázek 8: Zefyros Oktos XL – pohled shora.	35
Obrázek 9: Segmentace sledované lokality; rozdělení validačních dat; výsledná klasifikace.	36
Obrázek 10: Segmentace sledované lokality; rozložení tzv. Ground Truth dat v prostoru a jejich náhodné rozdělení do skupin kalibrační/validační; zelené značí zdravé stromy, žluté stromy napadené a červené stromy mrtvé.	38
Obrázek 11: Výsledky NN klasifikace napadených stromů pro dvě konkrétní období dohromady.....	41
Obrázek 12: Výsledky Decision Tree klasifikace napadených stromů pro dvě konkrétní období dohromady.....	41
Tabulka 1: Výměry jednotlivých zón v KRNAP (Schwarz, 2010).....	29
Tabulka 2: Označení období náletů s přesnými daty průběhu náletu.....	34

Tabulka 3: Poměr náhodně vybraných trénovacích a validačních dat 37

Tabulka 4: Přehled výsledků validačních dat pro všechny čtyři sledované období
dohromady..... 40

Seznam příloh

Příloha 1: Přehled výsledků klasifikace NN – chybové matice pro jednotlivé období

Příloha 2: Přehled výsledků klasifikace NN – chybové matice pro dvě sledované období

Příloha 3: Přehled výsledků klasifikace Decision Tree – chybové matice pro dvě sledované
období

10. Přílohy

Příloha 1: Přehled výsledků klasifikace NN – chybové matice pro jednotlivé období

Období A – 15. 6. 2017

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	9	3	1	13
zdravé	6	71	4	81
mrtvé	0	4	35	39
sum	15	78	40	133
Producer's Accuracy:	60 %	91 %	88 %	
User's Accuracy:	69 %	88 %	89.7 %	
Overall Accuracy:				86.5 %
Cohens Kappa:				0.75

Období B – 1. 8. 2017

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	7	1	1	9
zdravé	8	74	5	87
mrtvé	0	3	34	37
sum	15	78	40	133
Producer's Accuracy:	47 %	94.9 %	85 %	
User's Accuracy:	78 %	85.1 %	91.9 %	
Overall Accuracy:				86.5 %
Cohens Kappa:				0.74

Období C – 30. 8. 2017

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	4	0	1	5
zdravé	10	76	4	90
mrtvé	1	2	35	38
sum	15	78	40	133
Producer's Accuracy:	27 %	97.4 %	88 %	
User's Accuracy:	80 %	84.4 %	92.1 %	
Overall Accuracy:				86.5 %
Cohens Kappa:				0.74

Období D – 1. 10. 2017

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	9	4	3	16
zdravé	3	72	4	79
mrtvé	3	2	33	38
sum	15	78	40	133
Producer's Accuracy:	60 %	92.3 %	83 %	
User's Accuracy:	56 %	91.1 %	86.8 %	
Overall Accuracy:				85.7 %
Cohens Kappa:				0.74

Příloha 2: Přehled výsledků klasifikace NN – chybové matice pro dvě sledované období

Období AB

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	7	3	1	11
zdravé	8	68	4	80
mrtvé	0	7	35	42
sum	15	78	40	133
Producer's Accuracy:	47 %	87.2 %	88 %	
User's Accuracy:	64 %	85 %	83.3 %	
Overall Accuracy:				82.7 %
Cohens Kappa:				0.7

Období AC

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	5	3	1	9
zdravé	10	72	5	87
mrtvé	0	3	34	37
sum	15	78	40	133
Producer's Accuracy:	33 %	92.2 %	85 %	
User's Accuracy:	56 %	82.8 %	91.9 %	
Overall Accuracy:				83.5 %
Cohens Kappa:				0.7

Období AD

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	12	3	0	15
zdravé	2	69	7	78
mrtvé	1	6	33	40
sum	15	78	40	133
Producer's Accuracy:	80 %	88.5 %	83 %	
User's Accuracy:	80 %	88.5 %	82.5 %	
Overall Accuracy:				85.7 %
Cohens Kappa:				0.74

Příloha 3: Přehled výsledků klasifikace Decision Tree – chybové matice pro dvě sledované období

Období AB

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	1	5	0	6
zdravé	9	49	2	60
mrtvé	5	24	38	67
sum	15	78	40	133
Producer's Accuracy:	7 %	62.8 %	95 %	
User's Accuracy:	17 %	81.7 %	56.7 %	
Overall Accuracy:				66.2 %
Cohens Kappa:				0.42

Období AC

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	8	8	2	18
zdravé	2	49	3	54
mrtvé	5	21	35	61
sum	15	78	40	133
Producer's Accuracy:	53 %	62.8 %	88 %	
User's Accuracy:	44 %	90.7 %	57.4 %	
Overall Accuracy:				69.2 %
Cohens Kappa:				0.5

Období AD

User Class \ Sample	napadené	zdravé	mrtvé	total
napadené	8	12	0	20
zdravé	7	57	9	73
mrtvé	0	9	31	40
sum	15	78	40	133
Producer's Accuracy:	53 %	73.1 %	78 %	
User's Accuracy:	40 %	78.1 %	77.5 %	
Overall Accuracy:				72.2 %
Cohens Kappa:				0.52