

ČASOVÁ ZMENA VEGETAČNÝCH INDEXOV ODVODENÝCH ZO ZÁZNAMOV LANDSAT PRE DETEKCIU POŠKODENIA VEGETÁCIE V OCHRANNOM OBVODE JAVORINA (VYSOKÉ TATRY)

Mária HAVAŠOVÁ¹, Rastislav JAKUŠ², Ján FERENČÍK³

^{1,2} Ústav ekológie lesa, Slovenská Akadémia Vied, Ľudovíta Štúra 2, 960 53 Zvolen, Slovenská republika, maria.havasova@gmail.com, rasti.jakus@gmail.com

³ Výskumná stanica a Múzeum ŠL TANAP-u, 059 60 Tatranská Lomnica, Slovenská republika, jferencik@lesytanap.sk

Abstrakt

Satelitné snímky Landsat TM predstavujú bohatý zdroj údajov pre monitoring poškodenej vegetácie, v našom prípade je za príčinu poškodenia považovaný nálet lykožrúta smrekového (*Ips typographus* L.). Zo satelitných snímok za dvojice rokov 2006-2007 a 2010-2011 boli odvodené 4 typy vegetačných indexov NDMI (Normalized Difference Moisture Index), NDVI (Normalized Difference Vegetation Index), VCI (Vegetation Condition Index) a MSI (Moisture Stress Index). Na základe rozdielu hodnôt dvoch po sebe nasledujúcich rokov bolo stanovené poškodenie na viacerých úrovniach percentuálnej zmeny hodnôt vegetačného indexu. Správnosť klasifikácie satelitných snímok bola overená použitím derivátov leteckých snímok za roky 2007 a 2011. Poškodený les bol najlepšie klasifikovaný medziročným nárastom hodnôt indexu MSI o viac ako 12%. Použitie nárazníkových (buffer) zón okolo referenčných dát o šírke 1/2 pixla (15 m) zvýši presnosť automatizovanej klasifikácie poškodenej vegetácie.

Abstract

Landsat TM imagery is an excellent data source to monitor disturbed vegetation. In the study, the influence of Spruce Bark Beetle (*Ips typographus* L.) was considered as the main cause of disturbance. Satellite images per couples of years 2006-2007 and 2010-2011 have been converted into 4 types of vegetation indices: NDMI (Normalized Difference Moisture Index), NDVI (Normalized Difference Vegetation Index), VCI (Vegetation Condition Index) and MSI (Moisture Stress Index). Methodology of 'image differencing' (the difference between pixel value of vegetation index for two consecutive years) at several levels of percentage change reveals disturbed vegetation. Accuracy of classification of disturbed vegetation on Landsat images was related to aerial photography from 2007 and 2011. The best index to detect bark beetle attack was MSI at the level of 12% increase of the pixel value between two consecutive years. Overall accuracy OA can be further improved using *buffer zones* applied to reference dataset with width of half of the pixel size (15 m).

Kľúčové slová: Landsat, kappa, nárazníková zóna, lykožrút smrekový

Keywords: Landsat, kappa, buffer zone, spruce bark beetle

ÚVOD

Pôsobenie vetra a podkôrneho hmyzu patrí k najvýznamnejším disturbanciám v smrekových (*Picea abies* Karst.) ekosystémoch v strednej Európe [1]. Podkôrny hmyz spôsobuje výraznú úmrtnosť stromov v ihličnatých lesoch na celej rozlohe Vysokých Tatier a v priľahlých oblastiach. Pomocou diaľkového prieskumu Zeme sa najmä počas posledných desaťročí venuje pozornosť spektrálnym odpovediam (odrazivosti zachytenej na satelitných snímkach) postupne rozpadajúceho sa lesa či už pôsobením biotických alebo abiotických faktorov. Multispektrálne satelitné snímky sú široko používané pre presný a rýchly monitoring zmeny vegetácie horských ekosystémoch [4]. Zmeny vegetácie v čase je vhodné monitorovať najmä pomocou vegetačných indexov, ktoré dávajú do pomeru jednotlivé spektrálne kanály napr. snímok Landsat, a ktoré zároveň minimalizujú topografický efekt terénu a zmenu odrazivosti vplyvom rozdielného postavenia Slnka v čase vyhotovenia snímok [2], [3]. Prvé práce sa venovali detekcii silného poškodenia lesa [5] s ktorým súvisí rozpad porastovej a korunovej štruktúry [5]. Porovnaniu presnosti klasifikácie snímok použitím jedného alebo viacerých po sebe nasledujúcich rokov sa venujú Goodwin et al

[6], Meddens [7], [8] či Franklin [9]–[11]. Na Šumave sa dvoch typov zmien vegetácie – odumieraníu lesa spôsobeného lykožrútom smrekovým a ťažbe a následnou prirodzenou obnovou venuje Hais et al. [12]. Klasifikácii zdravotného stavu najmä listnatých lesov pomocou satelitných snímok Landsat sa na území Nízkych Tatier venoval Bucha [13]. Sledovanie rozšírenia lykožrúta smrekového pomocou nástrojov DPZ bolo v oblasti Vysokých Tatier prvýkrát popísané Jakušom et al. 2002 [14]. Ako najvhodnejší index pre detekciu bol stanovený index VCI (Vegetation Condition Index). Cieľom predkladanej práce je zistiť, či je možné uplatniť rôzne typy vegetačných indexov pre detekciu poškodenia lesa lykožrútom smrekovým použitím snímok Landsat a ich overením za použitia referenčných leteckých snímok stanoviť najpresnejšiu metódu monitorovania poškodenia.



Obr. 1 Študované územie nachádzajúce sa na území Vysokých Tatier, na slovensko-poľskej hranici

METODIKA

Záujmové územie sa nachádza v severovýchodnej časti Vysokých Tatier v Ochrannom obvode (O.o.) Javorina. (**Obr. 1**). Lokalita bola zvolená najmä kvôli prítomnosti veľkoplošného poškodenia ihličnatého lesa vplyvom lykožrúta smrekového od roku 2000 a kvôli dostupnosti referenčných leteckých snímok. Priemerný ročný úhrn zrážok na sledovanom území je 1600 mm, priemerná ročná teplota je približne 2°C, ročné rozpätie mesačných priemerných teplôt vzduchu je od -2°C v januári až 8°C v júli (dlhodobý priemer 1961-1990, [15]). Geologický substrát tvorí granit, z pôd na území nachádzame prevažne kambizeme a podzolové pôdy. Lesné porasty sa nachádzajú v rozpätí od 980 do 1700 m n.m. t.j. po hornú hranicu lesa. V najvyšších polohách boli v minulosti vykonávané ľudské zásahy no lesné ekosystémy si zachovávali prirodzený charakter. Lesné porasty na území O.o. Javorina zaberajú výmeru 3632 ha. Na území O.o. sú 3 Národné prírodné rezervácie a to Belianske Tatry, Javorová dolina a Bielovodská dolina s výmerou lesných porastov 3353 ha čo predstavuje 92,3% z celkovej plochy lesných porastov. Z drevín má najvyššie plošné zastúpenie smrek – 68%. Porasty nad 100 rokov zaberajú 37% rozlohy, 47% rozlohy lesov tvoria porasty od 121-140 rokov [16]. V práci boli uvažované iba porasty staršie ako 50 rokov t.j. na ploche 2413 ha. Celkom 32% svahov má severozápadnú orientáciu, južná orientácie na sledovanom území takmer absentuje [17]. V rôznych časových obdobiach boli aplikované rôzne spôsoby manažmentu lesa: pred 1994 – bezzásahový režim, 1995-1996 – intenzívny manažment (uplatňovanie lapákov, lapačov, insekticídov a asanačnej ťažby), od 1997 a neskôr „aktívny diferencovaný manažment“ t.j. diferenciácia kontrolných opatrení v rozsahu „bezzásahu“ až po opatrenia typu „klasický manažment“, rovnako boli intenzívne

využívané feromónové lapače. Prístupy boli uplatňované podľa platnej zonácie stanoveného územia na základe stupňa ich prirodzenosti a ekologickej stability [18].

Príprava snímok Landsat

Multispektrálne snímky Landsat TM5 majú 30 m priestorové rozlíšenia a poskytujú celkovo 7 kanálov zachycujúcich žiarenia vo vizuálnej a termálnej časti elektromagnetického spektra. Snímky boli vyhotovené od júla do septembra pre dvojice rokov 2006-2007 a 2010-2011 boli mozaikované do jednej snímky za rok s nulovou pokrývnosťou oblakov. Boli použité obe dráhy Landsat 187/26 a 186/26 prekrývajúce sa nad územím Vysokých Tatier. Následne boli všetky snímky ortorektifikované do súradnicového systému S-JTSK (Křovákove zobrazenie, Besselov elipsoid 1841).

Výpočet vegetačných indexov a ich časová zmena

Multispektrálne snímky Landsat sme použili na výpočet štyroch typov vegetačných indexov (ďalej „VI“) pre roky 2006, 2007, 2010 a 2011. Prvé dva sú indexy NDMI (Normalized Difference Moisture Index) a MSI (Moisture Stress Index) alebo „kanál 5/kanál 4“ [7]. Tieto indexy sú založené na kontraste medzi MIR (middle wave infrared – krátkovlnné infračervené, vlnová dĺžka 1.55 - 1.75 μm) a NIR (near infrared – blízke infračervené, vlnová dĺžka 0.76 - 0.90 μm) žiarenie a boli preukázané ako efektívne pri hodnotení poškodenia korún a v detekcii zmien lesa [5], [19]. NDMI je porovnateľné s metódou transformácie dát Landsat pre detekciu zmien vlhkosti „tasseled cap“ [20], ako matematickú operáciu však používa jednoduchú mapovú algebru. Pri odumieraní lesa medziročné hodnoty NDMI klesajú opadanie ihlíc vedie k zníženiu NIR odraznosti ale zvýšeniu hodnôt odrazivosti v blízkom infračervenom pásme kvôli vyššej obnaženej pôdy [12]. NDVI (Normalized Difference Vegetation Index) je najčastejšie používaným vegetačným indexom pri hodnotení zmien krajiny pokrývky a zakladá sa na zmene spektrálnej odrazivosti v červenej (R, spektrálny kanál 3, vlnová dĺžka 0.63 - 0.69 μm) a blízkej infračervenej NIR (kanál 4) časti elektromagnetického spektra. Index VCI (Vegetation Condition Index) dáva do pomeru blízke (kanál 4, NIR) a krátkovlnné infračervené žiarenie SWIR (short wave infrared, kanál 7, vlnová dĺžka 2.08 - 2.35 μm). Metóda rozdielu vegetačných indexov dvoch po sebe nasledujúcich rokov zvyčajne zmenu hodnoty vegetačného indexu v určenom časovom rozpätí a znižuje topografický efekt terénu a dopadajúceho oslnenia [3]. Zároveň však nedefinuje príčinu disturbance. V našej práci však na základe znalostí lokálnych pomerov považujeme za príčinu poškodenia vegetácie pôsobenie lykožrúta smrekového.

Metóda rozdielu hodnôt vegetačných indexov dvoch po sebe nasledujúcich rokov odhaľuje rozpad korún stromov [3], [21] a bola použitá pre detekciu zmeny (prírastok poškodenia lesa) pre dvojice rokov 2006-2007 a 2010-2011. Celkom sme stanovili 5 prahov pre detekciu zmeny – 7, 10, 12, 15 a 17 % zmeny hodnoty vegetačného indexu. Pre indexy NDMI a NDVI je poškodenie vegetácie vyjadrené poklesom hodnôt, pre VCI a MSI nárastom hodnôt indexu. Výpočty prebiehali na úrovni pixla.

Tab. 1 Použité vegetačné indexy a spôsob ich výpočtu.

| Vegetačný index | Výpočet | Literárny zdroj |
|-----------------|---------------------------------|-----------------|
| MSI | (kanál5/kanál4) | [7] |
| NDMI | (kanál4-kanál5)/(kanál4+kanál5) | [20] |
| NDVI | (kanál4-kanál3)/(kanál4+kanál3) | [22] |
| VCI | (kanál7)/(kanál4) | [23] |

Príprava referenčných dát

Vizuálnou interpretáciou leteckých infračervených snímok roku 2007 a 2011 boli zakreslené polygóny označujúce lokality odumretých stromov o veľkosti minimálne troch stojacich odumretých stromov. Snímky boli vyhotovené v septembri kvôli ľahšej identifikácii medzi smrekom a smrekovcom opadavým (*Larix decidua* Mill.) Zároveň boli determinované tzv. „masky lesa“ pre rok 2007 a 2011 z JPRL obsahujúcich viac ako 50% zastúpenie smreka a upravené podľa aktuálnych leteckých snímok. Pritom z nich boli vylúčené holiny spôsobené ťažbou ktoré majú podobné spektrálne charakteristiky odrazivosti ako má odumretý porast. Takto boli stanovené celkovo dva typy porastu – odumretý a zdravý les.

Analýza dát

Cohenov kappa koeficient (ďalej označené „K index“) je štatistickou mierou zhody medzi dvomi vektormi pre kvalitatívne/kategorické dáta. Kappa κ odráža rozdiel medzi skutočnou a náhodnou zhodou. Všetky analýzy sú založené na použití chybovej matice alebo kontingenčnej tabuľky [24] (**Tab. 2**).

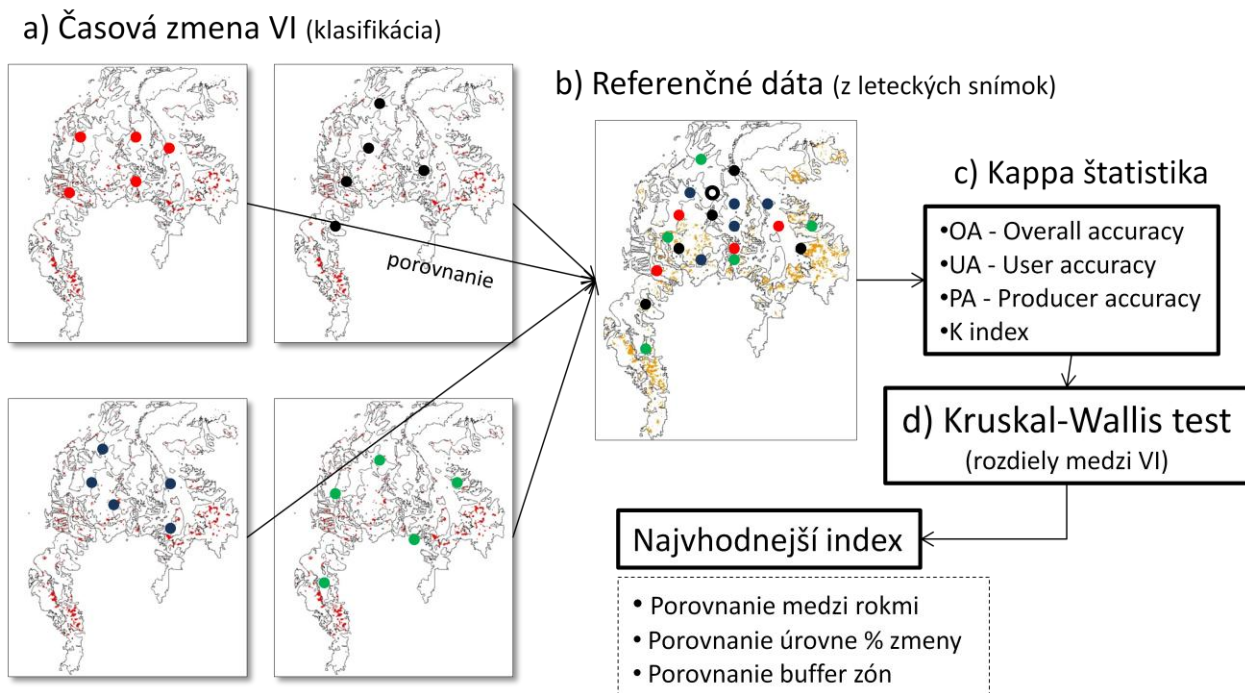
Tab. 2 Príklad kontingenčnej tabuľky potrebnej pre výpočet sledovaných hodnôt. Dve hodnotené triedy: poškod. les. = „poškodený les“ a „zdravý les“. UA.= „user accuracy“, PA = „producer accuracy“, celková presnosť OA = „overall accuracy“ je 86%

| | | referenčné dáta | | | |
|-----------------------------------|-------------|-----------------|------------|------------|------------|
| | | poškod. les | zdravý les | Σ | UA |
| klasifikácia Landsat snímky | poškod. les | 99 | 23 | 122 | 81.10% |
| | zdravý les | 9 | 98 | 107 | 91.60% |
| | Σ | 108 | 121 | 229 | |
| | PA. | 91.60% | 80.90% | | 86% |

Pre potreby stanovenia presnosti sme pre každý klasifikovaný raster z Landsat snímky vytvorili súbor približne 200 rovnako rozmiestnených náhodných referenčných bodov. Každý referenčný bod následne dostal dva atribúty. Prvý atribút tvorí kategória, v ktorej sa bod nachádza v klasifikovanom rastrovi, druhý atribút je kategória, v ktorej sa ten istý bod nachádza v referenčných leteckých snímkach. Ak v oboch dátach predstavuje bod iba jednu kategóriu (napr. poškodený les), vyhodnocujeme to ako zhodu klasifikácie s referenčnými dátami. Pre satelitné aj referenčné dáta pracujeme s dvomi kategóriami a to: „zdravý les“ a „poškodený les“. Pre súbor referenčných bodov nám týmto spôsobom vznikli 2 vektory údajov. Prvý vektor predstavuje triedu „zdravý“ alebo „poškodený les“ extrahovaný z klasifikovaného rastra, druhý vektor predstavuje rovnaké triedy, ale vygenerované z referenčných leteckých dát. Tieto 2 vektory vstupovali na výpočet kappa štatistiky v štatistickom programe R (balík irr [25] a asbio [26]).

Sledovali sme vybrané charakteristiky stanovenia presnosti: celková presnosť – (ďalej označené skratkou „overall accuracy - OA“) je vypočítaná podielom správne klasifikovaných bodov (suma hodnôt nachádzajúcich sa v hlavnej diagonále kontingenčnej tabuľky, **Tab. 2**) celkovým počtom bodov. Popri celkovej presnosti je možné podobne klasifikovať presnosť jednotlivých tried. Presnosť používateľa (ďalej „user accuracy“ - UA) pre triedu 1 („poškodený les“) a triedu 2 („zdravý les“) je miera spoľahlivosti mapy. Presnosť výrobcu, producenta mapy (ďalej označené „producer accuracy“ - PA) pre rovnaké hodnotené triedy odpovedá na otázku, s akou presnosťou môže byť daný stav mapovaný. Kappa koeficient (K index) je mierou celkovej zhody matice. V porovnaní s OA - podielom sumy hodnôt v diagonále k celkovému počtu bodov v matici – K index berie do úvahy aj hodnoty nespádajúce do diagonály [27]. V našej práci používame hodnoty UA a PA iba pre triedu 1 („poškodený les“), nakoľko stanovenie presnosti klasifikácie zdravého lesa nie je cieľom práce.


Pomocou neparametrickej Kruskal-Wallis analýzy variancie sme hodnotili rozdiely v skupine charakteristík presnosti pre rozličné druhy klasifikácie zoskupené podľa typu vegetačného indexu a podľa roku. Podobne sme testovali rozdiely medzi úrovňou percenta zmeny hodnoty pixla a pre rozličné šírky *buffer* zón. „Post-hoc test“ po Kruskal-Wallis tzv. „Multiple comparison test“ (Test viacnásobných porovnaní) následne porovnával jednotlivé dvojice metodík podľa faktorov a identifikoval rozdiely zistené analýzou variancie (balík R *pgirmess* [28]). Prehľadná schéma postupu práce je na **Obr. 2**.



Obr. 2 Schéma postupnosti práce. Pre každý klasifikovaný raster bol vygenerovaný súbor náhodných bodov (a). Tieto boli porovnané s referenčnými dátami (b). Dva vzniknuté vektorové súbory (1. z klasifikovaných dát, 2. z referenčných dát) boli porovnané Kappa štatistikou (c). Vybrané charakteristiky presnosti boli následne hodnotené testom Kruskal-Wallis (d) s cieľom určiť najvhodnejší index pre detekciu poškodenej vegetácie.

Aplikácia buffer zón a zohľadnenie polohovej presnosti dostupných dát

Polohová presnosť použitých leteckých snímok sa pohybuje v rozmedzí okolo 10-15 m, použité snímky Landsat dosahujú rovnako presnosť okolo 1/2 pixla (pri rozlíšení 30 × 30 m, [29]). Táto skutočnosť môže prispieť k zníženiu presnosti klasifikácie stanovenej pomocou snímok Landsat vzhľadom k referenčným leteckým snímkam. V tejto časti práce sme sa pomocou vytvorenia tzv. buffer zón okolo referenčných dát označených ako „poškodený les“ pokúsili o zvýšenie presnosti klasifikácie. Predpokladali sme, že ak buffrové zóny o rôznych šírkach obkolesujúce referenčné polygóny poškodeného lesa nebudú mať vplyv na výslednú presnosť, hodnoty stanovujúce presnosť klasifikácie a K index sa nebudú meniť. Ak použitie buffrových zón bude s narastajúcou šírkou buffru viesť k vyššej presnosti klasifikácie znamená to potrebu ich použitia pri hodnotení presnosti, s ohľadom na nižšiu polohovú presnosť referenčných dát, podobne ako hodnotil Delplace [30]. Kvôli podobne nepresným referenčným údajom vo svojej práci použil buffer zónu o šírke 40 m okolo referenčných polygónov označujúcich poškodený les, ktorú zároveň priradil do tejto kategórie. V našej práci sme sa zamerali na nájdenie najvhodnejšej šírky buffer zón. Buffrové zóny boli vytvorené okolo referenčných polygónov označujúcich „poškodený les“ vo vzdialenosti 0, 8, 15, 23, 30, 37 a 45 m, teda násobkov veľkosti pixla Landsat. Príklad polohovej nepresnosti je uvedený na **Obr. 3**.



Obr. 3 Príklad priestorovej nepresnosti porovnávaných klasifikovaných Landsat snímok a referenčných dát odvodených z leteckých snímok o poškodení lesa


VÝSLEDKY A DISKUSIA

Pomocou kappa štatistiky sme porovnali zhodu 2 vektorov pre každý klasifikovaný raster (líšiace sa typom VI ako aj % hodnotou zmeny hodnoty pixla). Výsledky boli zapísané vo forme kontingenčnej tabuľky (**Tab. 2**). Jej analýzou v programe R sme získali hodnoty K indexu, OA, PA a UA. Tieto charakteristiky vstupovali do následnej analýzy variácie a boli hodnotené Kruskal-Wallis testom pre faktory „vegetačný index (VI)“ a „rok“ (**Tab. 3**). Výsledok Kruskal-Wallisovho testu bol pri charakteristikách presnosti (OA, PA, UA a K index) štatisticky významný pri hladine významnosti $p < 0.05$ pre všetky sledované charakteristiky pre rôzne typy vegetačných indexov a pre oba sledované roky. Ak získaná hodnota Kruskal-Wallis testu je významná, znamená to, že najmenej jedna zo všetkých skupín vstupujúcich do analýzy je signifikantne odlišná od ostatných. Test viacnásobných porovnaní (Multiple comparison test after Kruskal-Wallis, príkaz „kruskalmc“ v balíku pgirmess v programe R) použitý v prípade významnosti Kruskal-Wallis testu, pomáha určiť, ktoré skupiny sa od seba navzájom odlišujú pri ich párovom porovnaní. Dvojice skupín s pozorovanými rozdielmi vyššími ako kritická hodnota sú považované za štatisticky odlišné na stanovenej hladine významnosti 0,05 [28].

Tab. 3 Výsledky testu Kruskal-Wallis pre charakteristiky presnosti, faktory: rok a vegetačný index (VI), ~ vo vzťahu ku. OA – *overall accuracy* (celková presnosť), PA – *producer accuracy* (presnosť výrobcu), UA – *user accuracy* (presnosť používateľa)

| | chi-squared | df | p-value |
|---------------|-------------|----|---------|
| OA~VI | 112.6525 | 3 | *** |
| OA ~rok | 52.0386 | 1 | *** |
| PA ~ VI | 118.0779 | 3 | *** |
| PA ~ rok | 5.6267 | 1 | *** |
| UA ~ VI | 112.1145 | 3 | *** |
| UA ~ rok | 61.9524 | 1 | *** |
| K index ~ VI | 121.5925 | 3 | *** |
| K index ~ rok | 48.8276 | 1 | *** |


Do testu viacnásobných porovnaní vstupovali hodnoty K indexu a hodnoty UA a PA. Hodnoty OA sme vynechali, nakoľko pri hodnotení presnosti klasifikácie zohľadňujú zhody v kontingenčnej tabuľke pre obe skúmané triedy – „zdravý“ a „poškodený les“. V prípade veľmi presnej klasifikácie „zdravého lesa“ a nízkej presnosti klasifikácie „poškodeného lesa“ môžu výsledné hodnoty (sumárne hodnoty klasifikácie za obe triedy) viesť k vysokým hodnotám presnosti, čo však neposkytuje informáciu o presnosti klasifikácie jednej, nami požadovanej triedy. Z tohto dôvodu do následných analýz vstupovali hodnoty K index (Obr. 4) a UA (Obr. 5) a PA (Obr. 6). Na hladine významnosti 0.05 môžeme povedať, že hodnoty K indexu (Obr. 4) pre dvojicu indexov MSI a VCI vykazujú podobnosť pre oba skúmané roky (v grafe označené symbolom a), naproti tomu nachádzame rozdiely medzi dvojicami MSI-NDMI a NDVI-VCI, pričom opäť podobné sú NDMI-NDVI (v grafe označené symbolom b), ktoré však dosahujú nižšie hodnoty K indexu. Podobne sme aplikovali test viacnásobných porovnaní pre hodnoty UA (Obr. 5). Na hladine 0.05 môžeme povedať že rozsahy hodnôt UA sa od seba štatisticky významne neodlišujú pre indexy MSI a VCI dosahujúce presnosti 60-100%, signifikantne odlišné sú dvojice MSI-NDMI a takisto NDVI-NDVI, pričom NDVI opäť dosahuje najnižšiu presnosť (10-50%). Test viacnásobných porovnaní aplikovaný na hodnoty PA (Obr. 6) indikuje s 95% pravdepodobnosťou, že presnosť klasifikácie indexov MSI a VCI je opäť štatisticky rovnaká, ako ďalšiu štatisticky podobnú dvojicu našiel VCI a NDVI.




Obr. 4 Viacnásobné porovnanie po teste Kruskal-Wallis pre hodnoty K indexu (v %). Na hladine významnosti 0.05 tvoria hodnoty presnosti indexov VCI a MSI jednu podobnú skupinu (a)

Skupina hodnôt presnosti indexu NDVI je štatisticky odlišná (nižšia) od presnosti klasifikácie ostatných vegetačných indexov (Obr. 5, Obr. 6, označené ako c). Na základe týchto výsledkov považujeme indexy MSI a VCI za najvhodnejšie pre medziročné hodnotenie poškodenia lesa lykožrútom smrekovým. Predpokladáme, že takisto index NDVI, ktorý dosahuje presnejšie hodnoty iba v roku 2011 môže byť na detekciu poškodenia prípadne použitý, ako bolo zistené v práci Havašová et al. 2013 [31]. V tejto práci nedosiahol rovnako podobné presnosti klasifikácie pravdepodobne kvôli nižším presnostiam klasifikácie

v roku 2007. Index VCI, ktorý dosahuje v hodnotení presnosti vysoké hodnoty, však pri aplikácii metódy rozdielu vegetačných indexov v roku 2007 nedokázal stanoviť takmer žiadne plochy poškodenia. To viedlo k nemožnosti vygenerovania dostatočného počtu náhodných bodov pre hodnotenia zhody klasifikácie rastra s referenčnými dátami. Do hodnotenia presnosti klasifikácie teda pre index VCI vstupovali iba hodnoty za rok 2011. Z tohto dôvodu uprednostňujeme pre následnú detekciu poškodenia lesa v ďalších prácach používanie indexov MSI a prípadne NDMI. NDVI je svetovo najviac používaným a rozšíreným indexom a môže byť použitý najmä na monitorovanie globálnych zmien a monitorovanie stresových udalostí. Predpokladáme teda jeho najvhodnejšie použitie pri mapách malých mierok, v modelovej oblasti v podmienkach Tatranskej Javoriny je však s veľkou pravdepodobnosťou nevhodný. Hodnoty K indexu pre NDVI dokonca dosahujú mierne záporné hodnoty, čo indikuje náhodnú zhodu referenčných a klasifikovaných satelitných dát. Na Slovensku je používaný najmä na monitorovanie nástupu fenologických fáz a odpoveď vegetácie na klimatickú zmenu pomocou produktov MODIS [32].



Obr. 5 Viacnásobné porovnanie po teste Kruskal-Wallis pre hodnoty UA (User accuracy, používateľská presnosť v %). Na hladine významnosti 0.05 tvoria hodnoty presnosti indexov VCI a MSI jednu podobnú skupinu (a), indexy NDMI a NDVI sú od seba odlišné (b, c).



Obr. 6 Viacnásobné porovnanie po teste Kruskal-Wallis pre hodnoty PA (Producer accuracy – výrobná presnosť v %). Na hladine významnosti 0.05 tvoria hodnoty indexov VCI a MSI štatisticky podobnú skupinu (a), zároveň sú si štatisticky podobné hodnoty pre indexy NDMI a VCI (b), rozsahy hodnôt NDVI sa od ostatných indexov štatisticky významne odlišujú (c)


Stanovenie najvhodnejšej medziročnej percentuálnej zmeny hodnoty vegetačného indexu

Po stanovení najvhodnejšieho vegetačného indexu sme sa v tejto časti práce zamerali na najvhodnejšiu percentuálnu zmenu hodnoty pixla z jedného roka na druhý. Opäť sme použili Kruskal-Wallisov test pre detekciu rozdielov medzi percentuálnou zmenou hodnoty pixla o 7, 10, 12, 15 a 17% pre jednotlivé

charakteristiky presnosti (**Tab. 4**). Pre všetky sledované charakteristiky presnosti môžeme na hladine významnosti 0.05 povedať, že sú navzájom odlišné v závislosti od % zmeny hodnoty pixla. Test viacnásobných porovnaní (**Obr. 7**) pre hodnoty K indexu s 95% pravdepodobnosťou preukázal, že dosahované hodnoty K indexu pri zmene 12 až 15% sú si štatisticky podobné a preukazujú najvyššie hodnoty presnosti (od 70 – do 90%). Môžeme povedať, že pre detekciu poškodenia lesa je najvhodnejší medziročný nárast hodnoty pixla (pre index MSI) o viac ako 12% (teda zároveň nárast vyšší o 15 a 17%).

Tab. 4 Výsledky Kruskal-Wallis analýzy variancie pre hodnotenie presnosti pre faktor: % zmena (7,10,12,15,17%) hodnoty pixla, OA – *overall accuracy* (celková presnosť), PA – *producer accuracy* (presnosť výrobcu), UA – *user accuracy* (presnosť používateľa)

| | chi-squared | df | p-value |
|-----------|-------------|----|---------|
| k value~% | 22.6525 | 4 | *** |
| OA ~ % | 22.7607 | 4 | ** |
| PA ~ % | 28.1548 | 4 | *** |
| UA~% | 17.3846 | 4 | ** |



Obr. 7 Viacnásobné porovnanie po Kruskal-Wallisovom teste pre hodnoty K indexu (v %), faktor: 7, 10, 12, 15, 17% zmeny hodnoty pixla. Rozsahy hodnôt K indexu pre 12 a 15% nárast hodnoty pixla nadobúdajú na hladine významnosti 0.05 podobné rozsahy hodnôt

Analýza použitia buffer zón


Rovnako pomocou Kruskal-Wallisovho testu sme zisťovali, či sa od seba štatisticky významne (na hladine významnosti 0.05) líšia presnosti klasifikácie pri uplatnení rôznych širok buffer zón vytvorených okolo referenčných polygónov označujúcich výskyt poškodeného lesa na základe leteckých snímok. Do analýzy variancie vstupoval ako faktor šírka buffer zóny a to šírka 0 m (t.j. bez aplikácie buffer zón), ďalej 8, 15, 23, 30, 37 a 45 m ako násobok veľkosti pixla. Referenčné body, v ktorých sme hodnotili zhodu klasifikovaných satelitných snímok s leteckými snímkami spadajúce do oblasti buffer zón boli odstránené z následnej analýzy a nevstupovali do sumárnej kontingenčnej tabuľky.

Na hladine významnosti 0.05 môžeme podľa výsledku testu Kruskal-Wallis (**Tab. 5**) povedať, že hodnoty presnosti (K index, OA a UA) sú od seba odlišné podľa šírky aplikovanej buffer zóny. Rozsahy hodnôt PA sa však od seba podľa tejto analýzy neodlišujú. Môžeme to vysvetliť skutočnosťou, že referenčné body použité pri hodnotení presnosti ležiace v oblasti *buffer zón* boli vylúčené z nasledujúceho Kruskal-Wallis testu. Z tohto dôvodu bolo vylúčené možné zvýšenie hodnôt „PA“ (ich priradenie v referenčných dátach ako „poškodený les“ ak v Landsat snímkach boli klasifikované v rovnakej triede). Ostatné hodnoty presnosti sa však zvyšovali.

Tab. 5 Výsledky Kruskal-Wallis analýzy variancie pre hodnotenie presnosti pre faktor: šírka buffer zóny (0, 8, 15, 23, 30, 37, 45 m), ~ vo vzťahu ku, OA – *overall accuracy* (celková presnosť), PA – *producer accuracy* (presnosť výrobcu), UA – *user accuracy* (presnosť používateľa)

| | chi-squared | df | p-value |
|----------------|-------------|----|---------|
| k value~buffer | 21.3084 | 6 | ** |
| OA ~ buffer | 21.3341 | 6 | ** |
| PA ~ buffer | 0 | 6 | ns |
| UA~buffer | 25.0514 | 6 | *** |

Zobrazenie pomocou krabicových grafov pre hodnoty K indexu (**Obr. 8**) indikuje stúpajúce hodnoty presnosti s rastúcou šírkou buffer zóny. Test viacnásobných porovnaní po teste Kruskal-Wallis preukázal, že rozsahy hodnôt presnosti dosahovaných pri použití zón o šírke 30 až 45 m sú si podobné na hladine významnosti 0.05. Vyššie hodnoty presnosti sú dosahované už pri aplikácii buffer zóny so šírkou 8 až 15 m (t.j. šírka $\frac{1}{4}$ až $\frac{1}{2}$ pixla) čo je zároveň povolená polohová presnosť snímok Landsat [29]. Na základe týchto výsledkov odporúčame v ďalších prácach týkajúcich sa presnosti klasifikácie satelitných snímok používanie buffer zón o šírke minimálne 15 m, čo zároveň korešponduje aj stanovenej presnosti leteckých snímok (polohová presnosť 10-15 m).



Obr. 8 Viacnásobné porovnanie po teste Kruskal-Wallis pre hodnoty K indexu, faktor: šírka *buffer* zóny: 0, 8, 15, 23, 30, 37, 45 m (násobky veľkosti pixla Landsat)

ZÁVER

V práci sme sa zamerali na stanovenie najvhodnejšieho vegetačného indexu pre detekciu poškodenia les ako dôsledku náletu lykožrúta smrekového vo Vysokých Tatrách (O.o. Javorina). Metodika medziročného rozdielu hodnôt vegetačného indexu a klasifikácia založená za percentuálnej zmene hodnoty pixla bola porovnávaná s referenčnými dátami – vizuálnou interpretáciou leteckých snímok vo forme .shp stanovujúcimi zdravý a poškodený les. Presnosť klasifikácie sme stanovili použitím súboru náhodne vygenerovaných referenčných bodov (približne 200, rovnaký počet v každej hodnotenej triede) pre každý klasifikovaný raster. Klasifikácia týchto bodov („poškodený“ alebo „zdravý les“) bola overená použitím referenčných leteckých snímok. Porovnaním zhody týchto dvoch vektorov sme získali súhrnnú kontingenčnú tabuľku. Jej vyhodnotením pomocou Kappa štatistiky sme zistili hodnoty presnosti danej klasifikácie. Pre každý klasifikovaný raster sme získali súbor hodnôt charakterizujúci presnosť klasifikácie: celkovú presnosť (*overall accuracy* - OA), používateľskú (*user accuracy* - UA), presnosť výrobcu (*producer accuracy* - PA) a hodnotu K indexu. Kruskal-Wallisova analýza variancie preukázala štatisticky významné rozdiely na hladine 0.05 pre hodnotené typy vegetačných indexov a dva sledované roky. Na základe testu viacnásobných porovnaní môžeme povedať, že na hladine významnosti 0.05 sú si presnosti hodnôt K indexu a UA podobné pre indexy

MSI a VCI a odlišujú sa od presností klasifikácie indexov NDMI a NDVI. Pre klasifikáciu poškodenia lesa považujeme za najvhodnejšiu medzoročnú zmenu hodnoty jej nárast o viac ako 12%. Použitím *buffer* zón o šírke 1/2 šírky pixla Landsat (15 m) obkolesujúcim referenčné dáta vo forme .shp označené ako „poškodený les“ sa nám podarilo zvýšiť celkovú presnosť klasifikácie, čím sme vzali do úvahy akceptovanú pozičnú presnosť ako Landsat snímok (15 m) tak snímok leteckých (10-15 m). .

V porovnaní s predchádzajúcou štúdiou [31] sa nám podarilo zvýšiť výsledky hodnotenia presnosti klasifikácie. Pravdepodobne je to najmä aplikovaním presnejšej masky lesa a vylúčenie pôsobenia ďalších typov disturbancií ako je napríklad obnovná ťažba, ktoré môžu mať podobné spektrálne charakteristiky ako suché stromy vznikajúce po nálete lykožrúta smrekového. Zároveň predchádzajúca práca pracovala s hodnotami všetkých pixlov na celom záujmovom území, čo viedlo k nadhodnoteniu v triede „les“ (ktorý je situovaný na väčšej ploche záujmového územia). Polohové nepresnosti neboli v predchádzajúcej štúdiu vyhodnotené, tento problém sa nám podarilo znížiť použitím *buffer* zón. V prvej štúdiu sme používali phi koreláciu alebo jednoduché hodnotenie pomocou kontingenčnej tabuľky. Použitím kappa štatistiky predpokladáme zvýšenie presnosti štúdie nakoľko berie do úvahy prípadnú náhodnú zhodu medzi triedami pre satelitné a letecké snímky.

POUŽITÁ LITERATÚRA

- [1] Svoboda, M., Fraver, S., Janda, P., Bače, R., Zenáhlíková, J.: Natural development and regeneration of a Central European montane spruce forest. In: For. Ecol. Manage., vol. 260, no. 5, pp. 707–714, Jul. 2010.
- [2] Filchev, L.: An Assessment of European Spruce Bark Beetle Infestation using WorldView-2 Satellite Data, in Best practices: Application of GIS technologies for conservation of natural and cultural heritage sites, 2012, pp. 9–16.
- [3] Lu, D., Mausel, P., Brondizio, E., Moran, E.: Change detection techniques. In: Int. J. Remote Sens., vol. 25, no. 12, pp. 2365–2401, Jun. 2004.
- [4] Nordberg, M. - Evertson, J.: Vegetation index differencing and linear regression for change detection in a Swedish mountain range using Landsat TM 1 and ETM 1 imagery. In: L. Degrad. Dev., vol. 149, no. 16, pp. 139–149, 2005.
- [5] Vogelmann, J. E. - Rock, B.N. Assessing Forest Damage in High-Elevation Coniferous Forests in Vermont and New Hampshire using Thematic Mapper Data. In: Remote Sens. Environ., vol. 24, pp. 227–246, 1988.
- [6] Goodwin, N.R., Coops, N. C., Wulder, M. A., Gillanders, S. N., Schroeder, T.A., Nelson, T.: Estimation of insect infestation dynamics using a temporal sequence of Landsat data. In: Remote Sens. Environ., vol. 112, no. 9, pp. 3680–3689, Sep. 2008.
- [7] Meddens, A. J. H. , Hicke, J. A., Vierling, L. A., Hudak, A. T.: Evaluating methods to detect bark beetle-caused tree mortality using single-date and multi-date Landsat imagery. In: Remote Sens. Environ., vol. 132, pp. 49–58, May 2013.
- [8] Meddens, A. J. H. , Hicke, J. A., Vierling, L. A.: Evaluating the potential of multispectral imagery to map multiple stages of tree mortality. In: Remote Sens. Environ., vol. 115, no. 7, pp. 1632–1642, Jul. 2011.
- [9] Franklin, S. E.: Remote sensing for sustainable Forest Management. Boca Raton: Lewis Publishers, 2001, p. 425.
- [10] Wulder, M. A., Dymond, C. C., Erickson, B.: Detection and monitoring of the mountain pine beetle. Victoria: Pacific Forestry Centre, 2004, p. 32.
- [11] Vogelmann, J. E., Tolk, B., Zhu, Z.: Monitoring forest changes in the southwestern United States using multitemporal Landsat data. In: Remote Sens. Environ., vol. 113, no. 8, pp. 1739–1748, Aug. 2009.

- [12] Hais, M., Jonášová, M., Langhammer, J., Kučera, T.: Comparison of two types of forest disturbance using multitemporal Landsat TM/ETM+ imagery and field vegetation data. In: *Remote Sens. Environ.*, vol. 113, no. 4, pp. 835–845, Apr. 2009.
- [13] Bucha, T. - Vladovič, J.: Klasifikácia zdravotného stavu lesov pomocou kozmických snímok Landsat TM na modelovom území Lomnistej a Vajskovskej doliny. In: *Lesn. časopis*, vol. 46, no. 2, pp. 117–128, 2000.
- [14] Jakuš, R., Grodzki, W., Ježík, M., Jachym, M.: Definition of Spatial Patterns of Bark Beetle *Ips typographus* (L .) Outbreak Spreading in Tatra Mountains (Central Europe), Using GIS. In *Ecology, Survey and Management of Forest Insect*, 2002, pp. 25–32.
- [15] Lapin, M., Faško, P., Melo, M., Šťastný, P., Tomlain, J.: Klimatické oblasti in in *Atlas krajiny Slovenskej republiky*, T. Hrnčiarová, Ed. Banská Bystrica: Ministerstvo životného prostredia Slovenskej republiky, 2002, p. 94.
- [16] Ferencík, J., Jakuš, R., Novotný, J., Slivinský, J.: Kalamita lykožrúta smrekového v oblasti Tatranskej Javoriny. In: *LES*, vol. 7, no. 98, 1998.
- [17] Grodzki, W., Jakuš, R., Lajzová, E., Sitková, T., Maczka, T.: Effects of intensive versus no management strategies during an outbreak of the bark beetle *Ips typographus* (L .) (Col.: Curculionidae, Scolytinae) in the Tatra Mts. in Poland and Slovakia. In: *Ann. For. Sci.*, vol. 63, pp. 55–61, 2006.
- [18] Turčáni, M., Novotný, J., Varinsky, J.: Hlavné problémy ochrany lesov v Štátnych lesoch TANAP-u z pohľadu LOS. in *Päťdesiat rokov starostlivosti o lesy TANAP-u*, 1999, pp. 63–70.
- [19] Cohen, W. B., Fiorella, M., Gray, J., Helmer, E., Anderson, E.: An Efficient and Accurate Method for Mapping Forest Clearcuts in the Pacific Northwest Using Landsat Imagery. In: *Photogramm. Eng. Remote Sensing*, vol. 64, no. 4, pp. 293–300, 1998.
- [20] Jin, S. - Sader, S. A.: Comparison of time series tasseled cap wetness and the normalized difference moisture index in detecting forest disturbances. In: *Remote Sens. Environ.*, vol. 94, no. 3, pp. 364–372, Feb. 2005.
- [21] Lyon, J. G., Yuan, D., Lunetta, R. S., Elvidge, C.D.: A Change Detection Experiment Using Vegetation Indices. In: *Photogramm. Eng. Remote Sensing*, vol. 64, no. 2, pp. 143–150, 1998.
- [22] Rouse, J. W. , Haas, R. H., Schell, J. A., Deering, D. W., Harlan, J. C.: Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. In: *Security*, no. September 1972, p. 371, 1974.
- [23] Jakubauskas, M. E. - Price, K. P.: Empirical Relationships between Structural and Spectral Factors of Yellowstone Lodgepole Pine Forests. In: *Photogramm. Eng. Remote Sens.*, vol. 63, no. 1, pp. 1375–1381, 1997.
- [24] Congalton, R. G.: A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. In: *Remote Sens. Environ.*, no. 37, pp. 35–46, 1991.
- [25] Gamer, M. , Lemon, J., Singh, P.: irr: Various Coefficients of Interrater Reliability and Agreement. R package, 2013.
- [26] Aho, K.: asbio: A collection of statistical tools for biologists. R package, p. 196, 2013.
- [27] Banko, G.: A Review of Assessing the Accuracy of and of Methods Including Remote Sensing Data in Forest Inventory. Laxenburg, 1998.
- [28] Giraudoux, P.: pgirmess: Data analysis in ecology. R package, p. 63, 2013.
- [29] Congalton, R. G.: Thematic and Positional Accuracy Assessment of Digital Remotely Sensed Data. in *Proceedings of the SEventh Annual Forest Inventory and Analysis Symposium*, 2005.

-
- [30] Delplace, D.: Etude de méthodes de détection de foyers de scolytes (Coleoptera , Curculionidae) dans l 'est de la France. Comparaison de techniques d'inventaires au sol, de surveillance aéroportée et de télédétection aérienne et satellitaire," Université Libre de Bruxelles, 2008.
- [31] Havašová, M., Burian, L., Jakuš, R., Ferenčík, J.: Predbežné hodnotenie poškodenia vegetácie pomocou satelitných snímok Landsat v O.o. Javorina. in Fórum mladých geoinformatikov, 2013, p. 9.
- [32] Bucha, T., Priwitzer, T., M. Koreň, M. Modelovanie fenologického vývoja lesných porastov pomocou vegetačného indexu NDVI odvodeného zo satelitných snímok MODIS. In: Lesn. Cas. - For. J., no. 2005, pp. 187–196, 2011.