Využitie UAV snímok na poloautomatickú detekciu výpadkov viniča vo vinohradoch Jelenca a Topoľčianok (Slovensko)

Adam ŠUPČÍK, Igor MATEČNÝ

Using UAV images for semiautomatic detection of row-gaps in vineyards in Jelenec and Topol'čianky (Slovakia)

Abstract: The use of UAV (Unmanned Aerial Vehicles) in precision viticulture leads to a more flexible and efficient approach to vineyard management. Images from UAV help determine the condition of the vineyard. Identification of the missing roots of the vineyard in a row by semi-automatic image classification and its comparison with manual classification is a goal of the paper. This study presents a new methodology for the segmentation of vine and row gaps. RGB (Red-Green-Blue) images, multispectral images, Near-Infrared (NIR) images, and Normalized Differential Vegetation Index (NDVI) images were tested and compared with manual classification. The percentage of row gap and the accuracy of individual images were determined. Object-oriented classification of the vine and row gaps in the buffer zone of the vineyard is a core of our method. Using geostatistical methods, such as zonal and logistic regression statistics, the accuracy of individual data in buffer zones was evaluated. Areas of interest were parts of vineyards in Jelenec and Topol'čianky. Success of the method detectom outage (compared to manual classification) was achieved by images in the RGB spectrum: 96.45% for the Jelenec vineyard and 82.61% for the Topolčianky vineyard. By this method, we quickly determine row gaps/vine which can be used to optimize or reduce the application of fertilizers to be used only on the vine. The method can be also used by inspection authorities to reveal the actual condition of the vineyard.

Keywords: row gap, object-based image classification, GIS, precision viticulture

Úvod

V súčasnej dobe sa vo vinohradníctve stále viac presadzujú moderné postupy precízneho vinohradníctva, ktorého hlavným cieľom je zvyšovať úžitkový potenciál vinohradu s menším negatívnym dopadom na životné prostredie. Aplikáciou moderného prístrojového vybavenia (bezdrôtové monitorovanie plodín, meteorologické stanice, senzory, závlahové systémy, kombajny na selektívny zber) a softvérového vybavenia sa dokáže zvýšiť efektívnosť vinohradu a využiť jeho potenciál (Zhang 2016). Prepojenie geografického informačného systému (GIS) s tradičným poľnohospodárstvom a vinohradníctvom prináša posun vo vyhodnocovaní úrodnosti a monitorovaniu zmien na poliach (Green 2012). Monitoring zmien na plodinách sa ne-zaobíde bez použitia globálneho navigačného satelitného systému (GNSS), snímok získaných z diaľkového prieskumu Zeme (DPZ) a analýzou v GIS prostredí (Blauth 2010).

Medzi najčastejšie používané snímky z oblasti DPZ patria satelitné snímky, ktoré dokážu zachytiť rozsiahle územia s rozlíšením pixelu 30 cm. Letecké snímkovanie dokáže zachytiť menšie územie, kde rozlíšenie snímky dosahuje 20 cm. Snímky z UAV dosahujú rozlíšenie 2 cm (Zarco-Tejada et al. 2013, Matese 2015). Vysoké rozlíšenie snímok napomáha hodnoverne identifikovať rad viniča, medziradie, príkmenné pásy a iné objekty na snímke (Comba et al. 2015).

DOI: https://doi.org/10.33542/GC2021-1-07

Zo snímok, ktoré zachytávajú rady viniča, sa dá ľahko detegovať priebeh radu a šírka radu (Wasser et al. 2015, Primicerio et al. 2017). Následná obrazová analýza snímok vinohradu vie poskytnúť rýchly a nedeštruktívny spôsob zachytenia presných informácií o množstve (Reis et al. 2012) a kvalite viniča, chorobách (Kerkech 2018), odhade výnosu (Colaço et al. 2020), množstve koreňov a výpadkov koreňov (Whalley 2013, Jurado 2020). Za výpadok môžeme považovať nesúvislý zápoj viniča v rade. Detekciou výpadkov viniča v radoch je možné vypočítať predpokladaný počet koreňov potrebných na podsadenie a optimalizovať aplikácie postrekov (Primicerio 2017). Poznanie skutočného stavu vinice môže byť účinným nástrojom kontroly, napríklad pre Poľnohospodársku Platobnú Agentúru alebo iné inštitúcie a agentúry zabezpečujúce dohľad nad poľnohospodárskou plochou.

Aplikácii objektovo-orientovanej analýzy obrazu v prostredí vinohradov sa venuje čoraz viac autorov: Primicerio et al.(2017), de Castro et al. (2018), Jiménez-Brenes et al. (2019), a iní, ktorí sa zameriavajú na detekciu radov viniča a identifikáciu koreňov.

Viacero typov kamerových snímačov umiestnených na palube UAV dokáže zachytiť rozdielne spektrálne pásma ako napríklad: RGB (Red-Green-Blue), NIR (Near-infrared), REG (Red edge), RED (Red) (Matese 2015), ktoré dokážu detegovať rozdielne vlastnosti rastlín.

NDVI index, NIR a multispektrálne snímky, sú v súčasnosti často využívané v precíznom poľnohospodárstve a vinohradníctve. Za použitia NDVI je možné identifikovať plochy, ktoré reprezentujú husto zelenú vegetáciu, alebo naopak plochy bez vegetácie, na základe množstva chlorofylu v listoch (Weier 2000). Pri multispektrálnej snímke môžeme sledovať vlastnosti, ktoré pri RGB snímkach nemôžeme vidieť voľným okom (napr. chemické vlastnosti, zdravotný stav lesov). Interpretáciou snímok NIR je možné odvodiť rôzne aspekty zaznamenaných objektov krajiny, napr. zdravotný stav plodiny (Holm et al. 1987).

Objektovo-orientovaná klasifikácia obrazu (OBIA) je metóda využívaná na segmentáciu a klasifikáciu krajinnej pokrývky, ktorá berie do úvahy nielen vlastnosti obrazu, ale aj zohľadňuje susedstvo pixelov. Vytvárajú sa jednotlivé homogénne objekty (segmenty) na základe nastaviteľných parametrov. Vznikajú logické zhluky pixelov, ktoré predstavujú segmenty, ktoré sa následne klasifikujú do jednotlivých tried (Blaschke et al. 2008). Výhodou tejto metódy oproti pixelovej klasifikácii je, že berie do úvahy štrukturálno-textúrne, spektrálne a relačné charakteristiky. Táto metóda zohľadňuje nielen vzdialenosť pixelov v priestore atribútov, ale aj v geografickom priestore, a okrem typizácie tak utvára aj geografickú regionalizáciu. Na základe týchto rozdielnych prístupov zachytáva priebeh hraníc objektov kvalitnejšie (Kurčíková 2013).

Cieľom práce je detekcia viniča a výpadkov koreňov v jednotlivých radoch vo vinohradoch na dvoch územiach v rôznych spektrách za využitia zonálnej štatistiky a logistickej regresie a následne komparácia výsledkov s manuálnou klasifikáciou za účelom otestovania, ktoré spektrum dosahuje najlepšiu úspešnosť metódy detegovať výpadok viniča z ortofotosnímky. Cieľ je identifikovať pomocou poloautomatickej detekcie vinič na snímkach vo vysokom rozlíšení s úspešnosť u viac ako 80 %. Autori Jiménez-Brenes et al. (2019) vo svojich prácach dosahujú danú úspešnosť. Záujmové územia sa volili na základe dostupných datasetov, na ktorých bolo možné identifikovať značný výpadok. Predkladaná práca predstavuje inovatívny prístup k hodnoteniu výpadkov viniča v radoch za využitia metódy OBIA v úzkych buffer zónach jednotlivých radov a následnej zónovej klasifikácie jednotlivých radov, kde je podľa zastúpenia plochy koruny viniča určený výpadok.

Metódy a dáta

Výpadky viniča sme analyzovali v dvoch vinohradoch (obr. 1), konkrétne v obciach Jelenec a Topoľčianky (Nitriansky samosprávny kraj, okres Nitra a Zlaté Moravce). Vinohrady sú súčasťou nitrianskej vinohradníckej oblasti, Topoľčianky patria do zlatomoravského vinárskeho rajónu a Jelenec do nitrianskeho vinárskeho rajónu. Z vinohradu sme si vybrali hony s najväčším zaznamenaným výpadkom. Hon v Jelenci má rozlohu 3,6 ha, 120 radov s priemernou dĺžkou 99,1 m. Hon v Topoľčiankach má rozlohu 5,7 ha, 92 radov s priemernou dĺžkou 222,5 m. V hone v Jelenci sú vysadené tri odrody: Rizling vlašský, Svätovavrinecké a Rulandské šedé, rok výsadby je 1980. Výpadky, ktoré vznikli v tomto hone, sú spôsobené starou výsadbou viniča. Hon v Topoľčiankach je vysadený v roku 2015 a odroda je Veltlínske zelené. V tomto hone došlo k vysokej miere neprijatia sanových sadeníc. V oboch vinohradoch sa používa stredný typ vedenia viniča (60 až 80 cm) (Pavloušek 2011).



Obr. 1. Lokalizácia výskumného územia

Snímky s rozlíšením menším ako 0,5 m na pixel umožňujú podrobný opis viniča (Marguerit et al. 2006). Vstupné dátové sady v Jelenci boli vyhotovené pomocou UAV e-Bee s kamerovým systémom Sequoia od spoločnosti Parrot, ktorý je vybavený štyrmi kamerami zachytávajúcimi štyro rozdielne spektrálne kanály: GREEN (zelený), RED (červený), REG (okraj červeného pásma) a NIR (blízky infračervený) s rozlíšením 1,2 Mpix a samostatnou 16 Mpix RGB kamerou. RGB kamera snímkuje vo veľkosti 4608 × 3456 pixelov a spektrálne kamery snímkujú vo veľkosti 1280 × 960 pixelov. Všetky kamery snímkujú v jeden okamih a vytvárajú súčasne päť snímok v rôznych spektrách (Classic eBee 2019). Kalibrácia zachyteného žiarenia prebehla pred samotným snímkovaním za použitia kalibračného terča určeného pre multispektrálnu kameru Parrot Sequoia. Snímky v oboch územiach boli vytvorené vo vrchole vegetačného obdobia. Územie bolo snímkované z výšky 100 m nad povrchom. Pri lokalite Jelenec sa snímkovalo dňa 2. 7. 2018 od 10. hodiny. Pri lokalite Topoľčianky bolo územie snímkované dňa 10. 7. 2017 o 11. hodine.

Pri podklade Topoľčianky sme mali k dispozícii už vyhotovené štyri datasety celého skúmaného územia. Datasety mali rozlíšenie 15 cm na pixel a boli transformované do kartografického súradnicového systému S-JTSK, pri datasete NDVI bolo rozlíšenie pixelu 20 cm. Pri lokalite Jelenec sme z jednotlivých snímok pomocou softvéru Agisoft (Agisoft Metashape Professional 2021) vyhotovili datasety záujmového územia. Do procesu vstupovalo celkovo 431 snímok z každého spektrálneho kanála. Rozlíšenie všetkých výsledných datasetov pri lokalite Jelenec dosahovalo 10 cm na pixel. Jednotlivé snímky boli priestorovo priradené pomocou 12 bodov na základe GNSS merania jednotlivých stĺpov vo vinohrade s presnosťou 5 cm s prístrojom Trimble Juno T41/5 s anténou R2. Posun snímok, ktorý vznikal medzi jednotlivými datasetmi, bol odstránený pomocou nástroja *Shift* v programe ArcMap.

Do procesu obrazovej analýzy vstupovali:

- RGB dataset (červený, zelený, modrý kanál),
- multispektrálny dataset (kompozícia zo snímok RGB, NIR, REG),
- NDVI (Normalizovaný Diferenčný Vegetačný Index), odvodený pomocou vzťahu:

$$NDVI = (NIR - RED) / (NIR + RED)$$
(1)

- NIR dataset (blízky infračervený kanál; 790 nm \pm 40 nm).

Detekciu viniča, výpadkov viniča a porovnanie efektívnosti použitia jednotlivých typov datasetov, sme následne realizovali pomocou nasledovných krokov:

- 1) objektovo-orientovaná analýza obrazu (OBIA) pre potreby detekcie radov,
- 2) zonálna štatistika,
- 3) logistická regresia.

Ako validačnú vrstvu pre vyhodnotenie úspešnosti metódy sme využili manuálnu klasifikáciu, s ktorou sme porovnávali výsledky poloautomatickej klasifikácie. Výsledkom tohto procesu bolo určenie celkového výpadku viniča v radoch, úspešnosť metódy detegovať výpadok na jednotlivých podkladoch a AUC (z angl. *area under the curve*) ukazovateľ, ktorý sa určuje z ROC (z angl. *Receiver Operating Characteristic*) krivky binárneho klasifikačného systému. Postup pri vykonávaní jednotlivých krokov je znázornený vo vývojovom diagrame (obr. 2). Celý proces je možné rozdeliť na štyri fázy nasledovne:

- 1) predpríprava dát,
- 2) segmentácia obrazu,
- 3) klasifikácia,
- 4) štatistické vyhodnotenie.

Pôvodné datasety boli orezané pomocou masky tvorenej len záujmovou plochou. Proces segmentácie a klasifikácie bol vykonávaný v prostredí eCognition Developer (Trimble 2014).

Na identifikáciu viniča a výpadkov sa použila *multi-resolution segmentácia* (MRS), kde najzásadnejším parametrom je *scale parameter* (parameter mierky), ktorý upravuje maximálnu heterogenitu vo výsledných objektoch. Vo všeobecnosti platí, čím väčší scale parameter, tým väčšie sú výsledné objekty (Drăguţ 2014). Ďalšími parametrami, ktoré sú potrebné pre správnu segmentáciu, sú nastavenia *shape* (tvarové vlastnosti segmentov) a *compactness* (kompaktnosť tvaru) (Benz et al. 2004) (obr. 3).

Parameter *Image Layer Weight* sa pri RGB snímkach nastavoval s rovnakou váhou pre každý kanál. Pri multispektrálnej snímke sa väčšia váha nastavila na kanál NIR. Rozdielne parametre segmentácie boli nastavené z dôvodu potreby vytvorenia tvarovo vhodných segmentov na jednotlivých podkladoch. Použitie rovnakých parametrov pri rozdielnych podkladoch by viedlo k výrazne rozdielnym hraniciam segmentov viniča. Parametre segmentácie boli rozdielne pre jednotlivé podklady (tab. 1).



lokalita	typ snímky	parametre segmentácie		
		scale parameter	shape	compactness
Jelenec	manuálna klasifikácia	70	0,1	0,5
	RGB	70	0,1	0,5
	multispektrálna	70	0,1	0,7
	NDVI	20	0,1	0,6
	NIR	90	0,5	0,9
Topoľčianky	manuálna klasifikácia	35	0,1	0,6
	RGB	35	0,1	0,6
	multispektrálna	10	0,1	0,7
	NIR	10	0,1	0,5
	NDVI	-	-	-

Tab. 1. Segmentačné parametre jednotlivých datasetov



Obr. 3. Porovnanie segmentácie pri zmene parametra shape: A = 0,1; B = 0,3; C = 0,6; D = 0,9

Utvorené segmenty boli následne poloautomaticky a manuálne klasiikované na dve klasifikačné triedy: (1) vinič a (2) okolie. V triede vinič boli obsiahnuté segmenty tvoriace rady viniča. V triede okolie boli všetky ostatné segmenty ako napríklad: príkmenný pás, vegetácia, medziradie, komunikácie a iné objekty situované na snímke. Poloautomatická klasifikácia bola vytvorená v programe eCognition a vychádzala práve zo segmentov vytvorených v tom istom programe. Zvolili sme si klasifikačné pravidlá z množín *Object features*, kde sme z množiny *Layer Values* zvolili premennú mean a pri množine *Texture* sme zvolili premennú GLCM kontrast. Správny výber trénovacích množín sme kontrolovali pomocou nástroja *Sample Editor*, kde sme hľadali hraničné hodnoty pri separácii jednotlivých tried.

Pre overenie celého procesu segmentácie a klasifikácie sme na malých skúšobných plochách vykonali aj manuálnu segmentáciu, ktorú sme následne porovnávali s výsledkom z programu eCognition. Segmenty vytvorené v programe eCognition sa zhodovali s manuálnymi segmentami na 94,6 %. Nedostatok bol v tom, že program pri segmentácii v niektorých prípadoch priradil tieň a vinič do jedného segmentu a tým pádom dochádzalo k nadhodnoteniu výsledku. Tieto nedostatky sa eliminovali pomocou manuálnej editácie segmentov.

Po segmentácii a klasifikácii sme pristúpili k redukcii dát. Túto redukciu sme vykonávali pomocou nástroja *Buffer*, čím vznikla zóna okolo každého radu. V tomto kroku sme používali program ArcMap. Šírka bufferu sa volila podľa šírky príkmenného pásu. V šírke príkmenného pásu sa vykonáva orba. Dochádza k rozrušovaniu trávnatého porastu a tým pádom sa na snímke dá ľahko identifikovať rad viniča. Rozhodli sme sa pre tento krok, aby sme odstránili ostatné plochy, ktoré nám nevstupovali do identifikácie viniča a výpadkov. Po orezaní bufferom sa nám trieda okolie zmenila na triedu výpadok, pretože sa odstránili prebytočné plochy medzi radmi a zostali len plochy, ktoré sa vzťahujú len na rad. V neskoršej fáze výskumu sa ukázalo, že využívanie buffer zóny vedie k zlepšenej identifikácii zavedených tried. Odstránením prebytočných plôch sa zmenší aj veľkosť súborov. Pri vinohrade v Jelenci mal tento buffer šírku 90 cm. Pri vinohrade v Topoľčiankach bola šírka 70 cm (obr. 4A). Podľa buffera sme orezali všetky vrstvy klasifikácie (obr. 4B).



Obr. 4. Buffer zóna okolo radov: A – buffer zóna; B – orezaná vrstva klasifikácie podľa buffer zóny

Vytvorené buffer zóny sme rozdelili na bunky pomocou nástroja *Create Fishnet* v ArcMape (obr. 5B). Rozmery týchto buniek boli šírka buffer zóny × 1 m na dĺžku. Tento medzikrok bol potrebný pre vstup do zonálnej štatistiky. Pri vinohrade Jelenec vzniklo 12 190 buniek a pri vinohrade Topoľčianky to bolo 20 623 buniek, čo tvorilo základ pre zonálnu štatistiku a logistickú regresiu.

Využitie zonálnej štatistiky v tejto práci napomohlo pri určovaní úspešnosti metódy detegovať výpadok v jednotlivých bunkách.

Metóda zonálnej štatistiky vychádza z rastra a polygónovej vrstvy, kde operácia je vykonávaná nad samotnou vrstvou a vytvára sa nová vrstva, ktorá obsahuje preddefinované bunky (Burian et al. 2015). V našom prípade išlo o rastrovú vrstvu klasifikáciou vymedzených tried (vinič, výpadok) daného radu. Informácie o zónach boli vo vrstve buniek, ktoré predstavovali polygónovú vrstvu (obr. 5B). Výsledkom zonálnej štatistiky bola informácia o podiele plochy viniča k ploche bunky (obr. 5C). Následne po prenásobení hodnotou 100 sme dostali percentuálny podiel plochy viniča v danej bunke.



Obr. 5. Ukážka princípu zonálnej štatistiky: vrstva A – raster, ktorý obsahuje hodnoty; vrstva B – zonálna vrstva; vrstva C – výsledok zonálnej štatistiky obsahujúci podiel plochy viniča k ploche bunky

Metóda logistickej regresie vychádza z binárnej škály a zaoberá sa odhadom pravdepodobnosti uskutočnenia javu (závislej premennej = prítomnosť viniča zistená poloautomatickou detekciou) vyjadreného pomocou poznaných javov (nezávislá premenná = prítomnosť viniča zistená manuálnou detekciou). Na vstupe využíva binárne premenné (Hosmer 2000), čiže ak jav nenastal (vinič je neprítomný) označí sa hodnotou 0 a naopak, ak sa jav vyskytol (vinič je prítomný) označí sa hodnotou 1. Túto reklasifikáciu sme vykonali na základe stanovenej podmienky, ktorá bunky klasifikuje do dvoch tried. Ak bunka obsahuje číslo väčšie ako 0,25 (resp. 25 %) priradí sa jej číslo 1, ak menšie ako 0,25 (resp. 25 %), nadobudne hodnotu 0. Inými slovami, ak sa v danej bunke nachádza viac ako 25 % podielu viniča, je vyhodnotená ako správna, čiže sa v bunke nenachádza výpadok. Hraničnú hodnotu podmienky sme stanovili na základe analýzy dát. Dochádzalo k tomu, že do bunky zasahovala zelená plocha viniča (výhon rastliny) z iného koreňa, ktorý sa nenachádzal v danej bunke, pričom bol v danej bunke viditeľný výpadok, preto sme pripustili, že 25 % plochy bunky môže obsahovať triedu vinič.

Po zadefinovaní týchto javov môžeme vytvoriť maticu 2×2 (obr. 6), kde nastávajú štyri predpokladané podmienky:

- skutočne pozitívny (*true positive*) nastane vtedy, ak testom označený vinič je skutočne vinič a teda manuálna aj poloautomatická klasifikácia preukázali v bunke viac ako 25 % plochy viniča,
- skutočne negatívny (*true negative*) nastane vtedy, ak testom označený výpadok je skutočne výpadok, platí keď poloautomatická aj manuálna klasifikácia určili výpadok v bunke, resp. menej ako 25 % plochy viniča,
- chyba I. typu (*false positive*) nastane, ak test označil vinič ako výpadok, tým pádom poloautomatická klasifikácia detegovala v bunke prítomnosť viniča a manuálna identifikovala výpadok,
- chyba II. typu (*false negative*) nastane, ak test označil výpadok ako vinič, čo zodpovedá situácii, keď poloautomatická vyhodnotila výpadok, ale manuálna označila bunku ako vinič.

klasifikácia		
poloautomatická manuálna	vinič	výpadok
vinič	vinič (true positive)	falošný výpadok (false positive)
výpadok	falošný vinič (false negative)	výpadok (true negative)

Obr. 6. Matica predpokladaných podmienok

Následne sme určili senzitivitu a špecificitu, ktoré popisujú výkonnosť testu a vstupujú do ROC krivky (z angl. *Receiver Operating Characteristics*), z ktorej sa určuje aj AUC index (plocha pod krivkou). ROC krivka predstavuje hodnotenie binárneho testu a taktiež najlepšie interpretuje výsledky logistickej regresie. Ak AUC dosahuje číslo 1, znamená to, že test dokázal odhaliť daný jav so 100 % presnosťou (obr. 7A). Ak AUC predstavuje hodnotu 0,5 (čo je už náhodný jav – obr. 7C) alebo menej, môžeme považovať test za nespoľahlivý (Fawcett 2006).



Obr. 7. Porovnanie viacerých AUC (plocha pod krivkou) indexov: AUC = 1 test sa označuje za perfektný; AUC = 0,7 test sa označuje za dobrý; AUC = 0,5 a menej, test sa považuje za neužitočný; Zdroj: Towards data science 2018

Týmto dostávame štatistický súbor, z ktorého vieme určiť úspešnosť metódy detegovať výpadok viniča získaných z jednotlivých snímok pomocou vzťahu:

$$\text{isp.met.det.výp.viniča} = \left(\frac{\sum true \ positive \ + \ \sum true \ negative}{\sum total \ value}\right) * 100$$
(2)

Vzťah predstavuje percentuálny podiel všetkých prípadov vinič/vinič (*true positive*) a všetkých prípadov výpadok/výpadok (*true negative*) zo sumy všetkých prípadov (*total value*).

Výsledky a diskusia

V predkladanej práci bol na základe poloautomatického procesu vyhodnocovaný podiel výpadku viniča v pravidelných plošných jednotkách (bunkách). Výsledok, ktorý sme dostali ako prvý z celého procesu, je percentuálny údaj hovoriaci o celkovom výpadku vo vinohrade (tab. 2).

lokalita	typ snímky	celkový výpadok [%]	úspešnosť metódy [%]	AUC
	manuálna klasifikácia	46,6	-	-
Jelenec	RGB	49,7	96,45	0,91
	multispektrálna	39,8	73,36	0,56
	NDVI	61,8	72,78	0,64
	NIR	48,7	72,26	0,56
	manuálna klasifikácia	33,45	-	-
	RGB	37,3	82,61	0,72
Topoľčianky	multispektrálna	37,2	75,47	0,61
	NIR	41,6	70,99	0,58
	NDVI	neurčené	neurčené	-

Tab. 2. Sumarizačná tabuľka v jednotlivých vinohradoch zobrazujúca parametre segmentácie a štatistické ukazovatele

Manuálna klasifikácia vstupovala do procesu ako validačná vrstva a z tohto dôvodu sme neurčovali úspešnosť metódy detegovať výpadok, ani AUC. Jediný parameter, ktorý sme určovali, bol výpadok. Dôležitým ukazovateľom nášho procesu je percentuálne vyjadrenie úspešnosti metódy detegovať výpadky viniča.

V oboch prípadoch môžeme vidieť, že najväčšiu úspešnosť predstavujú snímky v RGB spektre. Pri Jelenci je to až 96,45 % a pri Topoľčiankach je to 82,61 % úspešnosť. Len pri RGB podklade sme dosiahli cielenú úspešnosť zhody viac ako 80 %. Pri ostatných podkladoch

môžeme vidieť značný pokles v presnosti. Tento pokles môže byť spôsobený nižšou kvalitou ostatných podkladov, ktoré nedosahovali rozlišovaciu schopnosť ako podklad RGB. Pri overovaní presnosti pomocou AUC ukazovateľa sa nám preukázalo, že práve RGB podklad je najviac vhodný. Pri NIR podklade sa preukázalo, že identifikácia viniča a výpadku je náhodný jav, nakoľko sa blíži číslu 0,5. Nakoľko manuálna klasifikácia vychádzala z RGB snímky, tak do istej miery to mohlo spôsobiť zvýšenie presnosti, avšak predpokladáme, že je to nevýznamné zvýšenie presnosti.

Pri lokalite Jelenec môžeme sledovať výpadok 46,6 %, ktorý bol manuálne určený a považovaný za správny. Pri podklade RGB môžeme vidieť výpadok 49,7 %. Pri multispektrálnej snímke bol výpadok podhodnotený na 39,8 %. Program eCognition zaradil viac objektov do triedy vinič a dostali sme menší počet objektov s triedou výpadok. Pri NDVI indexe je možné zaznamenať presný opak. Podklad zaradil viac objektov do triedy výpadok, čo viedlo k zníženiu plochy viniča a výpadok dosiahol až 61,8 %. Toto nadhodnotenie mohlo spôsobiť, že pri klasifikácii program zaradil aj plochy s relatívne zdravým viničom do triedy výpadok, nakoľko tieto zdravé plochy viniča mali svetlejšiu farbu a rastlina s primeraným zdravotným stavom mala farbu tmavšiu, podobnú k farbe výpadku.

Manuálne určený výpadok v Topoľčiankach bol 33,45 %. Najbližší výpadok bol určený pri podklade RGB a to 37,2 %. Pri vypočítaní výpadkov sme vychádzali z plochy buffer zóny. Tu sa však preukázalo, že určenie výpadku nie je smerodajné a nedokáže určiť úspešnosť metódy detegovať výpadok z jednotlivých podkladov. Úspešnosť metódy detegovať výpadok sme určili pomocou výstupu zo zonálnej štatistiky a logistickej regresie, ktorá dokáže určiť úspešnosť jednotlivých podkladov. Asociácia medzi úspešnosť ou metódy a AUC je značne preukázateľná (tab. 2). Celkový výpadok slabo koreloval s úspešnosť ou a AUC indexom pri oboch vinohradoch, čím sme potvrdili, že celkový percentuálny výpadok nemá vplyv na úspešnosť identifikácie výpadku.

Manuálna klasifikácia vychádzala z RGB snímky vzhľadom na to, že sa z nej jasne identifikuje plocha viniča a výpadok, čo sa potvrdilo aj našou analýzou. Naopak, pri spektrálnych snímkach je možné sledovať podhodnotenú plochu viniča, z čoho vyplýva zvýšený výpadok (tab. 2).

Testovaním datasetov sme zistili, že dataset NDVI sa nepreukázal až tak vhodný ako sme predpokladali na začiatku nášho testovania. NDVI podklad určil aj väčší celkový výpadok. Predpokladáme, že jednotlivé segmenty boli zle vyklasifikované. Candiago et al. (2015) identifikovali výpadky vo vinohradoch a na paradajkovej plantáži. Tu autori pristúpili k hodnoteniu viacerých indexov ako napríklad NDVI, Green Normalized Difference Vegetation Index (GNDVI) a Soil Adjusted Vegetation Index (SAVI). NDVI taktiež nedosahoval uspokojivé výsledky.

Každá odroda vína má rozdielne nároky na pôdny chemizmus, na klimatické pomery, na hydrologické pomery a na topografické charakteristiky, ktoré priamo alebo nepriamo vplývajú na vinič (Súľovský 2016). Každá odroda ma iný spôsob vedenia viniča (Domin et al. 2017). Rozdielne odrody, ktoré sa vyskytovali na záujmových územiach, preukázali, že aj toto má vplyv na určovanie výpadkov, nakoľko samotné odrody majú rozdielny tvar koruny počas vegetačného obdobia.

Pri podklade z vinohradu v Jelenci, kde sme dosiahli 96,45 % úspešnosť, sme následnou analýzou zistili, že rozdiel, ktorý tvorí 3,55 %, predstavuje väčšinovo vrhnutý tieň z viniča. Program eCognition pri poloautomatickej klasifikácii určil, že tento tieň patrí do triedy vinič, čo v konečnom dôsledku nie je správne.

Pri podieloch plochy viniča k ploche bunky môžeme sledovať rozdielnosť určenia buniek pri manuálnej a poloautomatickej klasifikácii (obr. 8 a obr. 9). Pri poloautomatickej klasifikácii dochádzalo k tomu, že plochy viniča program vyhodnotil ako triedu výpadok. Program mal problém najmä pri už spomínaných tieňoch viniča.



Obr. 8. Porovnanie manuálnej (A) a poloautomatickej (B) klasifikácie RGB snímky vinohradu Jelenec s poukázaním na rozdielnosť určenia podielu plochy viniča k ploche bunky



Obr. 9. Porovnanie manuálnej (A) a poloautomatickej (B) klasifikácie RGB snímky vinohradu Topoľčianky s poukázaním na rozdielnosť určenia podielu plochy viniča k ploche bunky

Inovatívnym prvkom, ktorý sa aplikoval do procesu vyhodnocovania, je využitie buffer zóny okolo radov, pričom dochádza k eliminácii okolitých prvkov na snímke a znižuje sa aj objem dát, ktorý vstupuje do procesu klasifikácie a vyhodnocovania. V našom prípade sme volili šírku buffer zóny na šírku približne príkmenného pásu. Testovali sme viacero možností nastavovania šírky buffer zóny (obr. 10). Zistili sme, že užší buffer vedie k nesprávnosti, nakoľko nevie zachytiť celý rad. Ak neprechádza úzky buffer priamo cez rad, nedokáže zachytiť priebeh viniča v plnom rozsahu (obr. 10, červená čiara). Ukázalo sa, že vhodná šírka buffer zóny je oblasť na šírku príkmenného pásu (obr. 10, modrá čiara). Ak by sme do úvahy zobrali širšiu zónu, zahrnulo by to aj okolitú bylinnú vegetáciu v medziradí. V následnej analýze by to nadhodnocovalo plochy viniča, čím by sme dostali skreslené hodnoty výmery triedy viniča (obr. 10, žltá čiara).



Obr. 10. Rozdielna šírka buffer zóny vo vinohrade Jelenec: úzka šírka bufferu nezachytí celý rad (červená čiara); optimálna šírka (modrá čiara), široká šírka bufferu zachytáva aj okolitú zeleň (žltá čiara)

Costa et al. (2007) vo svojej práci klasifikovali vinič na snímke s rozlíšením 0,15 m na bunku. V tomto prípade autori brali do úvahy celú snímku aj s medziradím. Dosiahli vhodnú klasifikáciu obrazu so svojím algoritmom založeným na textúre obrazu, ktorý im dokáže zachytiť priebeh radov a určí výpadok. Isté chyby vznikali na kontakte trávy a viniča. Opierali sa o jednu snímku v odtieňoch šedej a neberú do úvahy spektrá. Vzniknutý problém by mohli eliminovať použitím buffer zóny okolo radu, nakoľko opisujú vznikajúce problémy s vegetáciou okolo viniča, a tým pádom dochádzalo k horšiemu výsledku klasifikácie.

Dôležitým faktorom je čas snímkovania. Ak dochádza k snímkovaniu v ranných alebo poobedňajších hodinách za slnečného počasia, vinohrad vrhá tieň (Echeverría et al. 2017), ktorý sa môže následne z leteckej snímky chybne klasifikovať. Ďalším dôležitým faktorom je aj vegetačné obdobie, počas ktorého sa snímkuje. Snímkovanie v skorej vegetačnej fáze alebo po zastrihnutí napomáha odhaliť reálnu plochu výpadku. Obdobie pred zastrihnutím do značnej miery eliminuje výpadok a rozširuje plochu viniča. Primicerio et al. (2017) poukazujú na problém pri identifikácii koreňov viniča zo zvislých snímok, kde dochádza k prekrývaniu vypadnutých koreňov viniča, ostatnými korunami viniča v rade. Na základe toho vytvoril postup, ktorý aj predikuje pozíciu kmeňa.

Na Slovensku práce zaoberajúce sa detekciou výpadkov a viniča absentujú, pričom niekoľko autorov sa venuje využívaniu technológie UAV pre detailné identifikovanie objektov na snímkach (Grznárová et al. 2019). Identifikácii pustnutiu vinohradov zo satelitných snímok sa venujú autori Karlík et al. (2017). Kurčíková a Soľanka (2013) poukazujú na rozdielnosť jednotlivých ortofotosnímok, kde určovali priebeh hraníc lesa s využitím OBIA, pri ktorých tieň degradoval záujmové plochy. Autori Echeverría et al. (2017) a Nolan et al. (2015) vo svojich prácach používali UAV snímky vo vysokom rozlíšení, kde presnosť detekcie viniča dosahovala viac ako 95 %, pričom porovnávali rozdielne klasifikačné metódy.

Delenne et al. (2010) vyvíjajú komplexný a automatický nástroj na detekciu nielen radov viniča, ale aj na vymedzenie celého územia vinohradu bez plánov pozemku, čo do značnej miery prispieva k širšiemu využitiu tohto nástroja.

Jeden z ďalších faktorov, ktoré do značnej miery znižujú úspešnosť metódy detegovať výpadok vo vinohrade, je slabé rozlíšenie snímok (Torres-Sánchez et al. 2014). To sa aj preukázalo na podklade NDVI pri Topoľčiankach. Na tomto podklade sa kvôli slabému rozlíšeniu podkladu (1 px = 20 cm) nedali jednoznačne identifikovať jednotlivé korene viniča (obr. 11). Tento fakt spôsoboval, že tento dataset bol snímkovaný s kamerou so slabším rozlíšením len 1,2 Mpix. Taktiež môžeme konštatovať, že napriek tomu, že spektrálne snímky mali podklady so slabším rozlíšením, dosahovali úspešnosť metódy okolo 70 %, čo môžeme považovať za uspokojivé výsledky.



Obr. 11. Slabá rozlišovacia schopnosť NDVI indexu pri snímke v lokalite Topoľčianky na ktorej nie je možné identifikovať vinič v radoch (červené línie)

Záver

Táto práca sa zameriava na hodnotenie leteckých snímok z UAV a určovanie výpadkov viniča v radoch. Výsledkom tejto štúdie je inovatívny poloautomatický postup identifikácie výpadkov viniča z UAV snímok. Výpadky sa analyzovali z RGB, NDVI, multispektrálnych a NIR snímok na dvoch rozdielnych vinohradov. Práca predstavuje unikátny prístup k hodnoteniu výpadkov viniča v podmienkach Slovenskej republiky.

Za hlavný prínos považujeme schopnosť analyzovať výpadok v bezprostrednom okolí viniča a to na šírku prikmenného pásu, tzv. buffer zóny. Tento prístup sa ukázal ako vhodný nakoľko sme eliminovali nežiadúce prvky ako sú okolitá vegetácia a medziradie. Taktiež sme do značnej miery eliminovali aj množstvo dát, ktoré nám vstupujú do výpočtu. Z prezentovaných výsledkov vyplýva, že na identifikáciu viniča a výpadkov našou zadefinovanou metódou sú vhodné RGB snímky vzhľadom na to, že pri týchto snímkach sme dosiahli najlepšie výsledky. V porovnaní s manuálnou klasifikáciou sme dosiahli úspešnosť metódy detekcie výpadku pre vinohrad Jelenec 96,45 % a pre vinohrad Topoľčianky 82,61 % v RGB snímkach, čo nám pre potvrdenie verifikoval aj AUC index. Dôležitým aspektom je aj veľkosť pixela, čo sa nám preukázalo na snímke s indexom NDVI pri Topoľčiankach. Pri precíznom vinohradníctve je potrebné pracovať so snímkami vo vysokom rozlíšení, pri zlej kvalite snímok môže dochádzať k horšej alebo až nedostačujúcej interpretácii snímok.

Inovatívny postup detekcie výpadku je vhodný na rýchlu analýzu UAV snímok a je využiteľný v praxi. Aplikáciou danej metódy je možné odhaliť oblasti, v ktorých absentuje vinič v jednotlivých radoch. Na miesta, kde plochy viniča predstavujú nízky podiel, je potrebné podsadiť nové korene.

Literatúra

- AGISOFT METASHAPE PROFESSIONAL 2021: Discover intelligent photogrammetry with Metashape. *Official Agisoft Website*. Retrieved from: https://www.agisoft.com.
- BENZ, U. C., HOFMANN, P., WILLHAUCK, G., LINGENFELDER, I., HEYNEN, M. 2004: Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3-4), 239-258. DOI: https://doi.org/10.1016/j.isprsjprs.2003.10.002.
- BLASCHKE, T., LANG, S., HAY, G. J. eds. 2008: Object-based image analysis Spatial concepts for knowledge-driven remote sensing applications. Berlin (Springer). DOI: https://doi.org/10.1007/978-3-540-77058-9.
- BLAUTH, D. A., DUCATI, J. R. 2010: A Web-based system for vineyards management, relating inventory data, vectors and images. *Computers and Electronics in Agriculture*, 71(2), 182-188. DOI: 10.1016/j.compag.2010.01.007.
- BURIAN, L., JENČO, M., RUSNÁK, M. 2015: GRASS GIS: Geovedné aplikácie. Bratislava (Univerzita Komenského v Bratislave, Prírodovedecká fakulta a Geografický ústav Slovenskej akadémie vied v Bratislave).
- CANDIAGO, S., REMONDINO, F., DE GIGLIO, M., DUBBINI, M., GATTELLI, M. 2015: Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote Sensing*, 7(4), 4026-4047. DOI: https://doi.org/10.3390/rs70404026.
- CLASSIC EBEE 2019: The professional mapping drone [cit. 2019-02-21]. Retrieved from: https://www.sensefly.com/app/ uploads/2018/05/eBee_EN.pdf.
- COLAÇO, A. F., TREVISAN R. G., KARP F. H. S., MOLIN, J. P. 2020: Yield mapping methods for manually harvested crops. *Computers and Electronics in Agriculture*, 177, 105693. DOI: https://doi.org/10.1016/j.compag.2020.105693.
- COMBA, L., GAY, P., PRIMICERIO, J., AIMONINO, D. R. 2015: Vineyard detection from unmanned aerial systems images. *Computers and Electronics in Agriculture*, 114, 78-87. DOI: https://doi.org/10.1016/j.compag.2015.03.011.
- COSTA, J. P., MICHELET, F., GERMAIN, C., LAVIALLE, O., GRENIER, G. 2007: Delineation of vine fields by segmentation of high resolution remote sensed images. *Precision Agriculture*, 8 (1), 95-110. DOI: https://doi.org/10.1007/s11119-007-9031-3.
- DE CASTRO, A. I., JIMÉNEZ-BRENES, F. M., TORRES-SÁNCHEZ, J., PEÑA, J. M., BORRA-SERRANO, I., LÓPEZ-GRANADOS, F. 2018: 3-D characterization of vineyards using a novel UAV imagery-based OBIA procedure for precision viticulture applications. *Remote Sensing*, 10(4), 584. DOI: https://doi.org/10.3390/rs10040584.
- DELENNE, C., DURRIEU, S., RABATEL, G., DESHAYES, M. 2010: From pixel to vine parcel: A complete methodology for vineyard delineation and characterization using remote-sensing data. *Computers and Electronics in Agriculture*, 70(1), 78-83. DOI: https://doi.org/10.1016/j.compag.2009.09.012.
- DOMIN, J. et al. 2017: Hrozno a víno ekologicky. Veľký Krtíš (Víno Natural Domin & Kušický).
- DRĂGUŢ, L., CSILLIK, O., EISANK, C., TIEDE, D. 2014: Automated parameterisation for multi-scale image segmentation on multiple layers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 88, 119-127. DOI: https://doi.org/10.1016/j.isprsjprs.2013.11.018.
- ECHEVERRÍA, P. C. OLMEDO, G. F., INGRAM, B., BARDEEN, M. 2017: Detection and Segmentation of Vine Canopy in Ultra-High Spatial Resolution RGB Imagery Obtained from Unmanned Aerial Vehicle (UAV): A Case Study in a Commercial Vineyard. *Remote Sensing*, 9(3), 268. DOI: https://doi.org/10.3390/rs9030268.
- FAWCETT, T. 2006: An Introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874. DOI: https://doi.org/10.1016/j.patrec.2005.10.010.

- GREEN, D. R. 2012: Geospatial Tools and Techniques for Vineyard Management in the Twenty-First Century. In Dougherty, P. H. ed. *The Geography of Wine: Regions, Terroir and Techniques*. Dordrecht (Springer), pp. 227-245. DOI: https://doi.org/10.1007/978-94-007-0464-0_13.
- GRZNÁROVÁ, A., MOKROŠ, M., SUROVÝ, P., SLAVÍK, M., PONDELÍK, M., MERGANIČ, J. 2019: The crown diameter estimation from fixed wing type of UAV imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-2/W13*, 337-341. DOI: https://doi.org/10.5194/isprs-archives-XLII-2-W13-337-2019.
- HOLM, A. M., BURNSIDE, D. G., MITCHELL, A. A. 1987: The development of a system for monitoring trend in range condition in the arid shrublands of Western Australia. *The Rangeland Journal (RANGELAND J)*, 9(1), 14-20. DOI: 10.1071/RJ9870014.
- HOSMER, D. W., LEMESHOW, S. 2000: Applied Logistic Regression. New Jersey (Wiley).
- JIMÉNEZ-BRENES, F. M., LÓPEZ-GRANADOS, F., TORRES-SÁNCHEZ, J., PEÑA, J. M., RAMÍREZ, P., CASTILLEJO-GONZÁLEZ, I. L. et al. 2019: Automatic UAV-based detection of Cynodon dactylon for site-specific vineyard management. *PLoS ONE*, 14(6). DOI: https://doi.org/10.1371/journal.pone.0218132.
- JURADO, J. M., PÁDUA, L., FEITO, F. R., SOUSA, J. J. 2020: Automatic grapevine trunk detection on UAV-based point cloud. *Remote Sensing*, 12(18), 3043. DOI: https://doi.org/ 10.3390/rs12183043.
- KARLÍK, L., GÁBOR, M., FALŤAN, V., LAUKO, V. 2017: Monitoring využívania vinohradníckych plôch: Prípadová štúdia Modra (Slovensko). *Geographia Cassoviensis*, 11(1), 22-32.
- KERKECH, M., HAFIANE, A., CANALS, R. 2018: Deep leaning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Computers and Electronics in Agriculture*, 155, 237-243. DOI: https://doi.org/10.1016/j.compag.2018.10.006.
- KURČÍKOVÁ, M., SOĽANKA, J. 2013: Klasifikácia lesných porastov s využitím pravých a tradičných ortofotosnímok. In Mokroš, M., Michňová, Z. eds. Fórum mladých geoinformatikov 2013: recenzovaný zborník, 02.-03. máj 2013, Zvolen. Zvolen (Technická univerzita vo Zvolene).
- MARGUERIT, E., COSTA F. A., AZAÏS, C. et al. 2006: High resolution remote sensing for mapping intra-block vine vigour heterogeneity. In van Leeuwen et al. eds. *Proceedings of the VIth International Terroir Congress*. Bordeaux (ENITA), pp. 286-291.
- MATESE, A., DI GENNARO, S. F. 2015: Technology in precision viticulture: A state of the art review. *International Journal of Wine Research*, 7, 69-81. DOI: https://doi.org/10.2147/IJWR.S69405.
- NOLAN, A. P., PARK, S., O'CONNELL, M., FUENTES, S., RYU, D., CHUNG, H. 2015: Automated detection and segmentation of vine rows using high resolution UAS imagery in a commercial vineyard. In Weber, T., McPhee, M., Anderssen, R. eds. *Proceedings -*21st International Congress on Modelling and Simulation, MODSIM2015. Broadbeach (MSSANZ), pp. 1406-1412. DOI: 10.36334/modsim.2015.f12.nolan.
- PAVLOUŠEK, P. 2011: *Pěstování révy vinné: moderní vinohradnictví*. Praha (Grada Publishing a.s.).
- PRIMICERIO, J., CARUSO, G. COMBA, L. et al. 2017: Individual plant definition and missing plant characterization in vineyards from high-resolution UAV imagery. *European Journal of Remote Sensing*, 50(1), 179-186. DOI: https://doi.org/10.1080/22797254.2017.1308234.
- REIS, M. J. C. S., MORAIS, E., PERES, E., PEREIRA, O. et al. 2012: Automatic detection of bunches of grapes in natural environment from color images. *Journal of Applied Logic*, 10(4), 285-290. DOI: https://doi.org/10.1016/j.jal.2012.07.004.

- SÚĽOVSKÝ, M., HRINÍK, D. 2016: Možnosti uplatnenia fyzickogeografických prístupov ako príspevku ku kvalitatívne orientovanej vinohradníckej produkcii. *Geographia Cassoviensis*, 10(2), 175-192.
- TRIMBLE 2014: *eCognition*® *Developer 9 Reference Book. Trimble Documentation*. München (Trimble Germany GmbH).
- TORRES-SÁNCHEZ, J., PEÑA, J. M., DE CASTRO, A. I., LÓPEZ-GRANADOS, F. 2014: Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103, 104-113. DOI: https://doi.org/10.1016/j.compag.2014.02.009.
- TOWARDS DATA SCIENCE 2018: Understanding AUC ROC Curve. *Medium*. Retrieved from: https://towardsdatascience.com/understanding-auc-roc-curve-68b2303cc9c5.
- WHALLEY, J., SHANMUGANATHAN, S. 2013: Applications of image processing in viticulture: A review. In Piantadosi, J., Anderssen, R. S., Boland, J. eds. MODSIM2013, 20th International Congress on Modelling and Simulation, Modelling and Simulation Society of Australia and New Zealand, December 2013. Adelaide (MSSANZ), pp. 531-537. DOI: https://doi.org/10.36334/modsim.2013.b1.whalley.
- WASSER, L. 2015: Mapping the invisible: The power of spectral remote sensing. *NEON –National Ecological Observatory Network* [cit. 2020-04-15]. Retrieved from: https://www.neonscience.org/impact/observatory-blog/mapping-invisible-power-spectral-remote-sensing.
- WEIER, J., HERRING, D. 2000: Measuring vegetation (NDVI & EVI). NASA Earth observatory [cit. 2020-04-12]. Retrieved from: https://earthobservatory.nasa.gov/features/MeasuringVegetation.
- ZARCO-TEJADA, P. J. GONZÁLEZ-DUGO, V., WILLIAMS, L. E. et. al. 2013: A PRIbased water stress index combining structural and chlorophyll effects: Assessment using diurnal narrow-band airborne imagery and the CWSI thermal index. *Remote Sensing of Environment*, 138, 38-50. DOI: https://doi.org/10.1016/j.rse.2013.07.024.
- ZHANG, Q. ed. 2016: *Precision Agriculture Technology for Crop Farming*. New York (CRC Press).

Poďakovanie: Príspevok vznikol vďaka grantu UK/295/2020 "Využitie diaľkového prieskumu Zeme a geografických informačných systémov v rámci precízneho vinohradníctva"

Adresy autorov

Mgr. Adam Šupčík Univerzita Komenského v Bratislave Prírodovedecká fakulta Katedra fyzickej geografie a geoinformatiky Ilkovičova 6, 842 15 Bratislava Slovensko adam.supcik@uniba.sk

RNDr. Igor Matečný, PhD.

Univerzita Komenského v Bratislave Prírodovedecká fakulta Katedra fyzickej geografie a geoinformatiky Ilkovičova 6, 842 15 Bratislava Slovensko igor.matecny@uniba.sk