

Modelovanie potenciálnej prirodzenej vegetácie s použitím metódy náhodných lesov. Prípadová štúdia: Malé Karpaty (Slovensko)

Marián GÁBOR, Lukáš KARLÍK, Igor MATEČNÝ, Vladimír FALTĀN

Modelling of Potential Natural Vegetation using Random forest algorithm. Case study: Malé Karpaty Mts. (Slovakia)

Abstract: Maps of the potential natural vegetation (PNV) are a useful tool for landscape planning, landscape and forest management, nature conservation and assessment of naturalness of landscape. Map of PNV offers possibility of showing not only scenario of natural vegetation and current environmental factors, but also an ecological description of territory. It is mostly constructed by methodology based on statistical analysis and expert knowledge. This paper shows the advantages of method based on object-based analysis and random forest algorithm with using topographical and soil predictors. In the process of modelling we have used soil properties, topographical attributes based on LIDAR data and vegetation relevés obtained from intensively management forests. Process of modelling was conducted using Object-based analysis to construct landforms and map of potential natural vegetation. The accuracy of results was tested with Kappa coefficient.

Keywords: ecological species group, soil interpolation, EBK regression prediction, object-based analysis, topographical properties

Úvod

Mapy potenciálnej prirodzenej vegetácie (PPV) prinášajú základné informácie o priestorovom rozšírení prirodzených biotopov a tiež prinášajú dôležité informácie pre potreby využívania krajiny, hodnotenia potenciálu vegetácie, ochrany prírody, zachovanie biodiverzity, environmentálneho plánovania, modelovania vplyvu klimatických zmien a mnohých ďalších odborov zameraných na manažment krajiny (Somodi et al. 2012). V súčasnej dobe je veľký záujem o pochopenie dôsledkov ľudskej aktivity na biosféru ako prostriedku na informovanie a uľahčenie optimálneho využívania krajiny a rozhodnutí o ochrane krajiny nielen vo verejnom, ale aj v súkromnom sektore zameranom na plánovanie využívania krajiny (Fore a Hill 2017).

Koncept PPV prvýkrát predstavil Faber (1937), avšak do širšieho povedomia ho dostal až Tüxen (1956). Podľa ich definície je PPV taký stav vegetácie, ktorý by sa vytvoril po odstránení vplyvu človeka na krajinu. Vychádza zo súčasného stavu krajiny a rešpektuje všetky nevratné zmeny prostredia ovplyvnené človekom, napr. umelé vodné nádrže, umelo obnažené povrchy, stavby, odvodnené mokrade a alúviá, i zmeny v priemyselných aglomeráciách. V tomto zmysle je PPV vedecká konštrukcia, ktorá odráža podmienky určitého miesta alebo lokality (Fischer et al. 2013). Oproti tomu mapy pôvodnej (rekonštruovanej) prirodzenej vegetácie znázorňujú vegetáciu, ktorá by za súčasných klimatických podmienok pokrývala zemský povrch bez vplyvu ľudskej činnosti počas historického obdobia (Falt'an 2005). Absencia striktno stanovených pravidiel pre tvorbu máp PPV má za dôsledok, že vo veľkom množstve prípadov sú založené na expertnom odhade autora. Preto možno vo viacerých prípadoch predpokladať, že odlišnosti medzi mapami PPV pre podobné územie nie sú spôsobené rozličnými stanovištnými podmienkami, ale aplikáciou rozličných prístupov autorov. Z toho dôvodu je koncept PPV niektorými autormi stále nepochopený a vedie sa o ňom diskusia (Chiarucci et al. 2010, Mucina 2010, Loidi et al. 2010, Somodi et al. 2012, Somodi et al. 2017, Loidi a Fernández-González 2012). V našom ponímaní odráža PPV charakter stanovišťa v termíne


fytoecenológie. Súčasná PPV vyjadruje súčasné podmienky stanovišťa vrátane predchádzajúcej histórie, a preto v koncepte PPV nie je relevantné, že stanovišťa môžu byť napadnuté novými druhmi, pretože tie nereflektujú očakávanú klimaxovú vegetáciu (Fischer et al. 2013).

Pri konštrukcii máp PPV zohrával v minulosti kľúčovú úlohu terénny výskum. Túto úlohu zachováva aj v súčasnosti, keďže slúži ako hlavný zdroj údajov. V súčasnej dobe získavajú vo výskume krajiny veľkú popularitu dáta z diaľkového prieskumu Zeme (DPZ), ktoré prinášajú nové spôsoby tvorby máp najmä pre zložitejšie dostupné územia, a to vďaka dostupnosti rôznych dát DPZ, ktoré prinášajú detailnejšie a časovo efektívnejšie získateľné informácie o krajine. Pri spracovaní dát DPZ sa do popredia dostávajú postupy založené na objektovo-orientovaných prístupoch, ktoré sa ukazujú ako vhodné pri riešení priestorových vzťahov v krajine. Objektovo-orientované analýzy sa využívajú v súčasnej dobe najmä pri mapovaní krajiny pokrývky (Gounaridis et al. 2015), mapovaní reálnej vegetácie (Mallinis et al. 2008), mapovaní foriem georeliéfu (Dragut a Blachke 2006), alebo pri tvorbe typológie súčasnej krajiny (Romportl et al. 2013) a mnohých ďalších prácach. Hlavnou výhodou objektovo-orientovaných prístupov je v porovnaní s klasickými prístupmi, kedy je územie rozčlenené do pravidelnej pixelovo založenej siete, to, že jednotlivé pixely sú priradené do objektov na základe viacerých parametrov. Objekty môžu byť teda popísané nielen na základe ich hodnoty, ale aj na základe textúry, typológie, heterogenity a priestorového vzťahu s ostatnými objektami (Gao 2009). Pri mapovaní PPV sa využívajú najmä moderné postupy založené na predpovedných modeloch PPV, ktoré určujú rozmiestnenie vegetácie v krajine na základe environmentálnych charakteristík s použitím odlišných modelov. Medzi najpopulárnejšie patria Bayesianská klasifikácia (Fischer 1990, Liu et al. 2009, Fischer et al. 2013), metóda náhodných lesov (Fore a Hill 2017, Divišek a Chytrý 2018), modelovanie pomocou Maxent (Hemsling a Bryn 2012, Janská et al. 2017), alebo metóda zvyšovania gradientu (Somodi et al. 2017). Franklin (2010) tvrdí, že metódy založené na strojovom učení (machine learning), prinášajú realističnejšie výsledky ako tradičné metódy mapovania. Tieto nové metódy uplatňujú najčastejšie výpočtové techniky založené na neurónových sieťach alebo klasifikačných stromoch pracujúcich s bodovo lokalizovanými informáciami.

Cieľom práce je vytvorenie detailnej mapy potenciálnej prirodzenej vegetácie založenej na prediktívnom modelovaní na príklade vybranej časti Malých Karpát, s použitím vegetačných a pôdných dát získaných terénnym výskumom a laboratórnymi analýzami, modelov georeliéfu, štatistických analýz a objektovo-orientovaného prístupu, ktorý prináša priestorovo orientované možnosti modelovania biotopov. K dôležitým výstupom práce patrí identifikácia nezávisle premenných geografických prediktorov, ktoré najvýznamnejšie ovplyvňujú rastlinné spoločenstvá záujmového územia a sú použiteľné pre modelovanie priestorovej distribúcie PPV. Naš výskum vychádza z geoeekologickej školy zameranej na detailný výskum krajiny na topickej úrovni a je spojený s použitím moderných metód.

Lokalizácia záujmového územia

Štúdia bola realizovaná v intenzívne využívaných hospodárskych lesoch Pezinských Karpát, ktoré sú časťou geomorfologického celku Malé Karpaty v Západných Karpatoch. Výskum bol vykonaný na transekte dlhom 15,2 km a širokom 800 m, ktorý pretína Pezinské Karpaty v juhovýchodno-severozápadnom smere s celkovou plochou 12,16 km². V rámci transektu boli umiestňované paralelne výskumné plochy pre vegetačné zápisy so vzájomnou vzdialenosťou 200 m (obr. 1). Vegetácia v území je reprezentovaná listnatými lesmi dubového a bukového vegetačného stupňa s dominantnými druhmi: buk lesný (*Fagus sylvatica*), dub zimný (*Quercus petraea* agg.), hrab lesný (*Carpinus betulus*), lipa malolistá (*Tilia cordata*) a javor horský (*Acer pseudoplatanus*). Záujmové územie sa nachádza v polohách s nadmorskou výškou od 187 do 583 m n. m., v geologickom podloží dominujú granity a vápence, na ktorých sa vytvorili najmä kambizeme a rendziny. Priemerné ročné teploty ovzdušia dosahujú +8 °C s priemernou hodnotou v januári -2,5 °C a priemerom v júli +18 °C. Priemerný ročný úhrn zrážok v nižších častiach územia je 680 mm a v najvyšších častiach územia 800 mm.



Obr. 1. Lokalizácia výskumných plôch a detailný pohľad na rozmiestnenie výskumných plôch

Metodický postup práce

Metodický postup práce môžeme rozčleniť do dvoch hlavných častí, pričom prvú predstavuje zber relevantných údajov a druhou je tvorba modelu PPV. Zber údajov sa skladá z terénneho zberu údajov zameranom na tvorbu vegetačných zápisov a odber pôdných vzoriek. Druhou časťou pri zbere údajov bolo získanie údajov v kancelárii, a to odvodenie geomorfologických charakteristík a interpolácia pôdných charakteristík. Druhou časťou je samotné modelovanie potenciálnej prirodzenej vegetácie.

Vegetačné dáta

Vegetačná databáza obsahuje 146 zápisov vytvorených na základe geobotanickej metodiky (Braun-Blanquet 1932) zachytávajúcej informácie o abundancii a dominancii cievnatých rastlín v lesných spoločenstvách. Z projektovaného počtu plánovaných zápisov nebolo v dôsledku prebiehajúcej ťažby porastov realizovaných 40. Vegetačné zápisy boli zhotovené na plochách s veľkosťou 400 m², pričom boli zaznamenané cievnaté rastliny vo všetkých etážach. Nakoľko sú listnaté lesy v strednej Európe charakteristické odlišným zložením bylinnej etáže počas jari a leta, bolo potrebné zapísať zloženie bylinnej vegetácie v letných (jún a júl 2016) aj jarných mesiacoch (apríl a máj 2017). Všetky vegetačné zápisy boli následne spracované v programoch TURBOVEG (Hennkens a Schaminée 2001) a JUICE 7 (Tichý 2002), kde sme v prvom kroku zľúčili vegetačné zápisy pre oba aspekty a v druhom kroku sme ich klasifikovali do jednotlivých vegetačných typov. Pred samotným modelovaním PPV sme zatriedili 146 vegetačných zápisov pomocou modifikovanej TWINSpan analýzy (Roleček et al. 2009) do vegetačných typov. TWINSpan analýza bola vykonaná v programe JUICE 7 (Tichý 2002). Na základe znalosti územia a Sørensenovej vzdialenosti s prahovou hodnotou 0,5 sme určili ako ideálny počet vegetačných skupín 5. Na základe náhodného výberu sme rozdelili skupiny druhov na tréningové údaje (75 %) a testovacie údaje (25 %), ktoré vstupovali do ďalšieho procesu.

Nezávislé environmentálne premenné

Pri veľkomierkovom výskume PPV má veľký význam podrobné poznanie vegetačných, geomorfologických a pôdných pomerov stanovišť. Detailný mikroklimatický výskum by si vyžadoval použitie terénnych meteostanic s niekoľkoročným radom meraní. V prostredí Malých Karpát sú klimatické pomery (najmä rozloženie priemerných teplôt vzduchu a množstva zrážok) závislé prioritne od nadmorskej výšky a expozície.

Pôdne vlastnosti sú reprezentované chemickými vlastnosťami z pôdných vzoriek odoberaných na výskumných plochách z vrchných 30 cm pôdy. Pôdne vzorky boli odobrané v septembri 2016 z každej plochy, kde bol realizovaný vegetačný zápis, a to vždy z centra plochy a súčasne aj z jej juhovýchodného a severozápadného rohu. Po odobratí boli vzorky pre každú plochu zmiešané, vysušené, homogenizované a preosiate cez sito s veľkosťou oka 2 mm. Pôdna reakcia (pH) bola meraná s použitím KCl (1:2,5), celkový dusík (N) bol určený pomocou Kjeldalovej metódy a obsah organického uhlíka (C) bol meraný s použitím spektrofotometrie. Ďalšie prvky boli merané s použitím Delta professional X-ray spektrometra (XRF), ktorý prináša rýchle a presné analýzy viacerých chemických prvkov súčasne (Kubala-Kukuš et al., 2015). Každá vzorka bola pomocou XRF spektrometra analyzovaná päťkrát a na základe aritmetického priemeru sme stanovili percentuálny obsah prvkov vo vzorke, pričom sme sa zamerali na obsah: hliníka (Al), vápnika (Ca), železa (Fe), horčíka (Mg), mangánu (Mn), olova (Pb), draslíka (K), síry (S), kremíka (Si) a zinku (Zn).

Vybrané georeliéfové charakteristiky boli odvodené z digitálneho modelu georeliéfu (DMR) v programe SAGA GIS (Conrad et al. 2015). DMR s polohovou presnosťou 1 m a vertikálnou presnosťou +/- 10 až 15 cm bol vytvorený Národným Lesníckym Centrom z lida-rového skenovania senzora LEICA ALS 70/CM z dvoch meraní z rokov 2014 (priemerná hustota bodov 4,88b/m²) a 2015 (priemerná hustota bodov 8,44 b/m²). Na vstupné DMR bol aplikovaný zhladzovací nástroj Mesh Denoise (Sun et al. 2007), ktorý je súčasťou SAGA GIS a slúži na zhladenie terénnych nepresností, pričom súčasne zachováva v dátach terénne hrany. Z rastra DMR (obr. 2) boli odvodené sklon georeliéfu, celková, vrstevnicová a spádnicová krivosť georeliéfu, celkový potenciálny ročný úhrn slnečného žiarenia, topografický index vlhkosti, vertikálna vzdialenosť k údolnici a topografický polohový index.

Interpolácia pôdných údajov


Interpolácia pôdných charakteristik bola vytvorená na základe použitia nástroja EBK regression prediction v programe ArcGIS Pro 2.0.0. (ESRI 2017). Pomocné prediktory použité na

interpoláciu boli zvolené na základe postupnej krokovej regresie pomocou vzostupného výberu (Forward Selection). Pomocou postupnej krokovej regresnej analýzy boli identifikované nezávislé pomocné prediktory prostredia, ktoré boli použité do interpolácie pôdnych charakteristík (tab. 1). Potencionálna multikolinearita medzi prediktormi bola odstránená aplikáciou PCA analýzy, ktorá je súčasťou nástroja EBK regression prediction. Kalibrácia nastavení modelu EBK bola uskutočnená zmenou vstupných parametrov iteráciami na základe porovnania priemernej chyby merania, sumy štvorcových chýb a priemernej štandardizovanej chyby.

Tab. 1. Základné charakteristiky vybraných chemických prvkov, prediktory použité pri interpolácii

Názov prvku	Minimum	Maximum	Modus	Medián	Priemer	Prediktory
Draslík	0.939	2.322	1.778	1.6055	1.563	VDChN; EI
Dusík	1	35	1	4	5.692	SI
Horčík	0	0.976	0	0.632	0.627	EI
pH	1.23	6.44	3.47	3.52	3.604	SR; TPI
Uhlík	0.64	8.49	1.35	1.68	2.092	EI; VDChN; PrC
Vápnik	0.143	3.704	0.223	0.339	0.422	VDChN; SR; South, East
Zinok	0	0.015	0.004	0.004	0.004	EI; VDChN
Železo	0.599	4.525	1.894	1.971	1.922	EI; VDChN

Vysvetlivky: VDChN – vzdialenosť ku údolnici, EI – nadmorská výška, SI – sklon, SR – potenciálne množstvo dopadajúceho slnečného žiarenia, TPI – topografický polohový index, PrC – spádnicová krivosť, South – južnosť, East – východnosť



Obr. 2. Základné charakteristiky georeliéfu modelového územia získané použitím technológie LIDAR

Predspracovanie získaných údajov

Údaje o georeliéfe a chemických vlastnostiach pôdy boli normalizované z pôvodných hodnôt na hodnoty 0 – 100 na základe vzťahu:

$$y = (x - \min(x)) * 100 / (\max(x) - \min(x)),$$

kde y je normalizovaná hodnota a x je pôvodná hodnota rastra.

Normalizované hodnoty sme následne podrobili korelačnej analýze, pričom na základe Spearmanovho korelačného koeficientu sme vylúčili premenné, ktoré vykazovali vysokú mieru párových korelácií; konkrétne išlo o pôdne charakteristiky: olovo, kremík, hliník a síru.

Vegetačné snímky sme ešte pred samotným spracovaním rozdelili do dvoch podmnožín na tréningové (75 %) a testovacie (25 %) dáta. Rozdelenie bolo spravené na základe stratifikovaného náhodného delenia v programe STATISTICA 10, kde sme brali do úvahy aj lokalizáciu výskumných plôch v rámci transektov.

Modelovanie potenciálnej prirodzenej vegetácie

Modelovanie PPV sme vykonali v prostredí programu eCognition Developer 9.0 (Definiens 2009). Ako základné jednotky pre modelovanie PPV sme využili geotopy, ktoré považujeme v zmysle definície Minár et al. (2001) za homogénne jednotky. Pomocou nástroja multiresolution segmentation sme získali segmenty, ktoré môžeme považovať na základe zvolených regionalizačných charakteristík z fyzickogeografického pohľadu za homogénne jednotky – geotopy. Geotopy sme považovali za totožné s formami reliéfu, ktoré sme vyčlenili na základe práce (Dragut a Blaschke 2006) ktorí odporúčajú využívať ako vyhraničujúce faktory nadmorskú výšku, sklon georeliéfu, spádnicovú a vrstevnicovú krivosť. Na stanovenie veľkosti geotopu sme využili nástroj ESP2 (Dragut et al. 2014). ESP2 produkuje graf lokálneho rozptylu (LV graf) v závislosti od meniacej sa veľkosti segmentov (resp. parametra mierky), od ktorého je veľkosť segmentov priamo závislá. Na základe identifikovaných extrémov v LV grafe sme následne identifikovali parameter mierky segmentácie, ktorý má zásadný vplyv na výsledok segmentácie.

Závislé premenné vstupujúce do tvorby mapy potenciálnej prirodzenej vegetácie sú údaje o vegetačných typoch obsiahnutých v tréningovej databáze (109 vegetačných zápisov), ktoré sme priradili príslušajúcim geotopom. Pre takto zvolené geotopy (s priradeným vegetačným typom) bola vyjadrená základná popisná štatistika obsahujúca nezávislé environmentálne premenné reprezentované charakteristikami reliéfu a chemickými vlastnosťami pôdy. Následne boli tieto objekty a ich atribúty analyzované pomocou nástroja SEaTH (Nussbaum et al 2006). Pomocou SeaTHu boli odhalené najvýznamnejšie vlastnosti, na základe ktorých možno vegetačné typy oddeliť. Tieto vlastnosti boli v ďalšom kroku použité ako nezávislé klasifikačné kritériá vegetačných typov aplikované na zvyšných objektoch.

Ako klasifikačný nástroj bola zvolená metóda náhodných lesov (random forest algorithm), ktorá prináša lepšie výsledky v porovnaní s ďalšími bežne využívanými klasifikačnými postupmi (Fore a Hill 2017). Metódu vyvinul Breiman (1996), ktorý ju následne v roku 2001 vylepšil (Breiman 2001). Do modelu vstupovali ako závislé premenné informácie získané o geotopoch, do ktorých boli priradené jednotlivé vegetačné typy. Nezávislé premenné boli odhalené použitím nástroja SEaTH (tab. 3). Algoritmus náhodných lesov použitý v programe eCognition Developer 9.0 bol kalibrovaný v programe STATISTICA 10. V práci bolo použitých 500 regresných stromov, pričom na každom uzle regresného stromu sme zvolili deväť prediktorov (parameter mtry), ktoré zodpovedajú najčastejšie využíwanej hodnote reprezentovanej 1/3 všetkých prediktorov použitých pri tvorbe modelu. Pri ďalších parametroch sme vychádzali z preddefinovaných hodnôt.

Celková presnosť klasifikácie bola overená na základe vegetačných typov, ktorú tvorili testovacie údaje (37 vegetačných zápisov), ktoré boli oddelené ešte pred klasifikáciou od pôvodnej množiny údajov a neboli použité do klasifikácie. Celková presnosť klasifikácie bola

určená na základe percentuálnej zhody s vegetačnými zázpismi a kappa koeficientom, ktorý berie do úvahy pravdepodobnosť náhodnej zhody a využíva sa ako miera náhodnosti výsledkov klasifikácie (Cohen 1960).

Výsledky

Vegetačné typy

Na základe vykonanej TWINSpan analýzy bolo 146 vegetačných zázpisov zatriedených do 5 vegetačných typov (tab. 2).

Tab. 2. Kombinovaná synoptická tabuľka percentuálnej frekvencie (stálosť) a vernosti (ϕ koeficient, horný index).

Číslo vegetačného typu	I	II	III	IV	V
Počet plôch	29	48	10	19	44
<i>Fagus sylvatica</i>	100 ^{36,6}	98 ^{34,5}	10	79	39
<i>Luzula luzuloides</i>	34^{52,0}	-	-	-	2
<i>Moehringia trinervia</i>	66 ^{38,7}	2	-	5	77^{51,5}
<i>Tithymalus amygdaloides</i>	31 ^{27,8}	-	10	11	11
<i>Dentaria bulbifera</i>	55 ^{21,0}	63^{29,4}	10	47	-
<i>Acer pseudoplatanus</i>	-	22 ^{14,6}	20	21	-
<i>Acer campestre</i>	3	2	30 ^{21,2}	37 ^{30,8}	2
<i>Carpinus betulus</i>	-	-	90 ^{54,8}	32	64 ^{27,5}
<i>Quercus petraea</i> agg.	3	4	80 ^{48,8}	32	50 ^{17,1}
<i>Tilia Cordata</i>	-	-	60 ^{35,3}	79 ^{56,3}	2
<i>Galium sylvaticum</i> agg.	3	-	50^{63,6}	-	-
<i>Hedera helix</i>	-	-	30 ^{19,2}	47 ^{43,0}	2
<i>Impatiens parviflora</i>	3	6	80 ^{33,5}	84 ^{37,7}	59 ^{12,5}
<i>Melica uniflora</i>	-	-	100^{66,5}	74 ^{39,1}	7
<i>Galium aparine</i> agg.	-	-	40 ^{23,4}	58 ^{45,4}	7
<i>Fraxinus excelsior</i>	-	2	-	42 ^{56,5}	2
<i>Corydalis cava</i>	-	-	10	63^{68,7}	-
<i>Galium odoratum</i>	10	-	10	47 ^{30,3}	43 ^{25,3}
<i>Geranium robertianum</i> agg.	7	-	50	53 ^{22,2}	50 ^{19,4}
<i>Ficaria bulbifera</i>	10	-	-	47 ^{31,4}	50 ^{34,6}
<i>Alliaria petiolata</i>	-	-	50	53 ^{22,3}	57 ^{26,7}
<i>Polygonatum multiflorum</i>	-	-	10	42 ^{51,9}	-
<i>Anemone ranunculoides</i>	-	8	-	16 ^{25,8}	-
<i>Calystegia sepium</i> agg.	7	2	30	32	61 ^{39,7}
<i>Viola reichenbachiana</i>	10	-	-	11	18 ^{19,3}
<i>Mycelis muralis</i>	10	-	-	26	45 ^{39,2}
<i>Cerasus avium</i>	7	-	-	5	16 ^{22,4}
<i>Carex sylvatica</i>	-	4	10	-	11 ^{14,3}
<i>Urtica dioica</i>	41	2	20	11	75 ^{49,4}
<i>Rubus fruticosus</i> agg.	17	14	-	11	50 ^{40,8}
<i>Poa nemoralis</i> agg.	3	-	-	5	16 ^{25,4}

Vysvetlivky: Vegetačný typ číslo I – Bukové kyslomilné lesy podhorské, II – Bukové kvetnaté lesy podhorské, III – Dubovo-hrabové lesy karpatské, IV – Lipovo-javorové lesy, V – Dubovo-hrabové lesy karpatské antropogénne; Pozn. V tabuľke sú uvedené len diagnostické druhy pre vybrané vegetačné skupiny s $\phi \geq 0,25$. Diagnostické druhy pre jednotlivé vegetačné typy sú uvedené hrubým písmom.

Vytvorené skupiny druhov nekorešpondovali s tradičnými vegetačnými jednotkami. Na základe katalógu biotopov Slovenska (Ružička et al. 1996) sme zatriedili väčšinu vytvorených vegetačných typov do jednotlivých typov biotopov. V prvej skupine (Bukové kyslomilné lesy podhorské) s prevládajúcim druhom stromového poschodia *Fagus sylvatica*, v bylinnom poschodí s indikačným druhom *Luzula luzuloides* a dominantnými druhmi *Moehringia trinervia* a *Tithymalus amyglaoides*. *Dentaria bulbifera* a *Fagus sylvatica* sú indikačnými druhmi pre druhú skupinu druhov (Bukové kvetnaté lesy podhorské). Tretia skupina (Dubovo-hrabové lesy karpatské) je v stromovom poschodí reprezentovaná druhmi *Quercus petraea*, *Carpinus betulus* a *Tilia cordata*, pričom indikačnými druhmi bylinného poschodia sú *Melica uniflora*, *Galium sylvaticum* agg. a *Impatiens parviflora*. Štvrtá skupina (Lipovo-javorové lesy) je tvorená indikačnými druhmi *Tilia cordata*, *Fraxinus excelsior*, *Corydalis cava* a *Polygonatum multiflorum* a piatu skupinu (Dubovo-hrabové lesy karpatské antropogénne) možno charakterizovať dominanciou *Carpinus betulus* a *Quercus petraea*. Za indikačné druhy piatej skupiny možno označiť druhy z bylinnej etáže *Moehringia trinervia*, *Urtica dioica*, *Mycelis muralis* a *Ficaria bulbifera*.

Tvorba mapy potenciálnej prirodzenej vegetácie

Na základe výsledkov nástroja ESP2 bol stanovený parameter mierky pre segmentáciu (tvorbu geotopov) na hodnotu 71 (obr. 4). Pre objekty s jasne definovanými skupinami druhov (tréningové dáta) boli určené najvýznamnejšie premenné vedúce k vzájomnej separácii vegetačných typov (tab. 3). Do výsledného modelu najviac prispievajú jednotlivé charakteristiky uvedené v obr. 3, pričom najväčší vplyv majú najmä horčík a nadmorská výška, a z objektových funkcií dominujú najmä priemer, maximum a minimum. Naopak najmenej prispievajú textúrne vlastnosti jednotlivých geotopov. Výsledok klasifikácie možno stotožňovať s mapou potenciálnej prirodzenej vegetácie (obr. 4). Na základe mapy PPV vidíme, že najväčšiu plochu zaberá vegetačný typ Bukových kvetnatých lesov (4,65 km²), ktorý zaberá najmä najvyššie položené časti územia. Dubovo-hrabové lesy karpatské antropogénne zaberajú 3,74 km² a nachádzajú sa najmä v severozápadnej nížinatej časti územia, dôvod uvádzania tejto kategórie ako samostatnej pri tvorbe mapy PPV je v tom, že sa diametrálne odlišuje od Dubovo-hrabových lesov karpatských (1,03 km²), ktoré sú typickým predstaviteľom tohto vegetačného typu a dominujú vo východnej časti územia smerom od Podunajskej nížiny. Bukové kyslomilné lesy podhorské (1,76 km²) dominujú v najvyššie položených častiach územia a v prípade nižšie položených častí sa nachádzajú na miestach s nedostatkom živín, čo je reprezentované aj najchudobnejším bylinným poschodím. Najmenšiu plochu, 1 km², zaberajú Lipovo-javorové lesy, ktoré sú azonálnym spoločenstvom dominujúcim na najstrmších svahoch.

Celková presnosť klasifikácie na základe porovnania s vegetačnými typmi, ktoré nevstupovali do klasifikácie, dosiahla hodnotu 78 % s hodnotou koeficientu kappa 0,701. Presnosť zaradenia jednotlivých tried so skupinami druhov uvádza tab. 4. Na základe tabuľky vidíme, že najväčšiu presnosť majú vegetačné typy 3 a 5, čo sú Dubovo-hrabové lesy. Presnosť 82 % dosiahli aj bukové kvetnaté lesy podhorské, naopak najnižšiu presnosť, 44 %, majú bukové kyslomilné lesy, čo môže byť spôsobené vysokou podobnosťou s predošlým vegetačným typom. Lipovo-javorové lesy ako azonálne spoločenstvo mali celkovú presnosť 77 %, čo považujeme taktiež za uspokojivý výsledok. Kappa koeficient nám hovorí o tom, že nakoľko je daná presnosť náhodná a nakoľko je spôsobená kvalitou modelu, pričom hodnoty blízke 1 hovoria o presnosti spôsobenej modelom, za uspokojivé hodnoty sa považujú hodnoty kappa koeficientu nad 0,61. Hodnota 0,351 získaná pri Bukových kyslomilných lesoch sa zaraďuje medzi nízke hodnoty a celkovo znižuje kvalitu výsledného modelu.


Tab. 3. Prediktory prostredia a objektové funkcie vstupujúce do tvorby mapy PPV

Názov objektovej funkcie	Prediktory prostredia
Priemerná hodnota (Priemer)	El, Ca, C, Mg
Maximum	El, Ca, C, Mg
Minimum	El, Ca, C, Mg
Smerodajná odchýlka (SD)	Ca, C, Mg, K
Všesmerná textúra Haralicka pre homogenitu (Homogenita)	pH
Všesmerná textúra Haralicka pre uhol druhého pohybu (Uhol)	TWI, C, Mg, K, pH
Všesmerná textúra Haralicka pre smerodajnú odchýlku (SD2)	Ca, C, Mg, K
Všesmerná textúra Haralicka pre koreláciu (Korelácia)	pH


Skratky sú vysvetlené v tab. 1

Tab. 4. Výsledná presnosť mapy potenciálnej prirodzenej vegetácie s detailným pohľadom na výslednú presnosť jednotlivých tried

Číslo vegetačného typu	Celková presnosť (v %)	Kappa
Bukové kyslomilné lesy podhorské	44	0,351
Bukové kvetnaté lesy podhorské	82	0,717
Dubovo-hrabové lesy karpatské	100	1
Lipovo-javorové lesy	77	0,739
Dubovo-hrabové lesy karpatské antropogénne	99	0,986



Obr. 3. Prispievanie vybraných nezávislých premenných do výsledného modelu PPV.
Skratky sú vysvetlené v tab.1 a tab.3



Obr. 4. Výsledná mapa potenciálnej prirodzenej vegetácie s hranicami geotopov

Diskusia

Vegetačnou pokrývkou a jej mapovaním sa zaoberajú odborníci z rozličných vedných oblastí, geobotanici, ekológovia i vegetační geografi, každý zo svojho uhla pohľadu, s použitím rôznych metodických postupov a rôznym využitím získaných informácií v praxi. Vegetačným mapovaním z geografického pohľadu sa zaoberali napr. Tivy (1993), Jäger (1997), Halfmann (2000), pričom za dôležité považujú okrem samotného zachytenia vegetácie územia i jej stanovištné podmienky. V ostatnom období sa do popredia dostáva interdisciplinárny prístup a využitie moderných štatistických metód a prostredia GIS pri modelovaní vegetačných pomerov. Zároveň sa striktnejšie oddeľujú pojmy reálna vegetácia (v zmysle súčasného stavu vegetačných pomerov), pôvodná (rekonštruovaná) prirodzená vegetácia a potenciálna prirodzená vegetácia (Tüxen 1956). V práci sme snažili o detailné zachytenie vplyvu súčasného stavu vegetácie a stanovištných podmienok na modelovanie potenciálnej prirodzenej vegetácie, naše výsledky diskutujeme i so štúdiami s rovnakou problematikou realizovanými vedcami iných oblastí výskumu ako je geografia.

Výsledná mapa PPV dosiahla celkovú presnosť 74 %. Presnosť bola zistená použitím testovacej podmnožiny dát získanej terénnym prieskumom a obsahujúcej 37 výskumných zápisov s rovnomerným zahrnutím všetkých typov porastov vyskytujúcich sa v území. Podľa Fischer et al. (2013) nie je vhodné používať na kalibráciu modelu iba časť dát, pretože rozdiely medzi pozorovanou a modelovanou distribúciou jednotiek PPV nie sú spôsobené chybami modelu, ale rôznymi stanovištnými podmienkami. Títo autori rovnako zastávajú názor, že nie je

možné využívať testovacie a tréningové údaje na overenie presnosti modelu, keďže tieto údaje sú navzájom autokorelované. Na druhej strane je delenie na testovacie a tréningové údaje frekventovane používané, a to nie len pri tvorbe máp PPV, ale aj v rôznych ekologických štúdiách (Hörsch 2003, Mallinis et al. 2008, Olivero et al. 2013, Szymura et al. 2014, Zhang et al. 2014, Walker et al. 2017), a preto sme sa tento spôsob overenia presnosti modelu rozhodli aplikovať i my v našej práci.

Dosiahnuté výsledky možno považovať za porovnateľné s prácou Liu et al. (2009), ktorí dosiahli celkovú presnosť 66,9 %, avšak model týchto autorov bol vytvorený bez použitia vegetačných zápisov a v nižšej rozlišovacej úrovni, čo by ho malo v porovnaní s našim modelom zvyhodňovať pri hodnotení presnosti klasifikácie. Lepšie výsledky presnosti klasifikácie v porovnaní s nami dosiahli Fore a Hill (2017), ktorých model PPV dosiahol presnosť od 73 % po 86 %, avšak aj v tomto prípade boli vyššie hodnoty presnosti dosiahnuté znížením rozlišovacej úrovne mapovania v porovnaní s našou prácou. Rozdiely v presnosti medzi jednotlivými prístupmi môžu byť zaťažené nie len rôznou úrovňou mapovania, ale aj rôznorodosťou mapovaných území, pretože druhovo menej bohaté územia vedú pri správnej klasifikácii najrozšírenejších druhov k výrazne lepším výsledkom celkovej presnosti. Naopak, Fischer et al. (2013), Somodi et al. (2012), Somodi et al. (2017) a ďalší autori vo svojich prácach neuvádzajú hodnotenie celkovej presnosti výsledného modelu PPV vôbec.

Pri výbere prediktorov prostredia pre účely modelovania PPV je potrebné brať do úvahy ich vplyv na závisle premennú, pričom netreba do analýzy zahrnúť vždy všetky dostupné premenné (Fore a Hill 2017). Z tohto dôvodu je potrebné vybrať len relevantné informácie o stanovištiach, aby nedochádzalo ku zbytočnej korelácii prediktorov. Zároveň nie je vhodné využívať len geoštatistické postupy, ale využívať aj expertnú znalosť územia. S narastajúcim počtom nevhodne zvolených prediktorov okrem poklesu výpovednej hodnoty klasifikačného modelu dochádza k enormnému predĺženiu výpočtového času modelovania.

Výsledky boli interpretované na základe širokej databázy spojenej s odberom pôdnych vzoriek počas detailného geoeologického výskumu zameraného na tvorbu veľkomierkových máp s cieľom detailne spoznať všetky relevantné podmienky prostredia v hospodársky intenzívnejšie obhospodarovateľných lesoch a vyjadriť ich plošne na príklade transektu. V tom prípade môže výskyt niektorých druhov zodpovedať ekologickému driftu. Pri porovnaní nami vytvorenej mapy s mapou PPV od Michalka et al. (1986) sme v území neidentifikovali Lužné lesy podhorské a horské, ktoré autori identifikovali v doline Stupavského potoka, avšak v našom prípade neboli identifikované tieto lesy ani priamo v teréne. Michalko et al. (1986) taktiež v území identifikovali aj Dubové kyslomilné lesy, ktoré sme počas terénneho výskumu v území neidentifikovali a namiesto nich sme identifikovali Dubovo-hrabové lesy karpatské. Autori taktiež vo svojej práci identifikovali aj Dubové nátržníkové lesy, ktoré sa ale podľa Ružička et al. (1996) viažu na vnútorné karpatské kotliny. Pri ostatných typoch porastov sme dosiahli podobné plochy rozlohy aj s podobnou lokalizáciou v rámci skúmaného územia s výnimkou Dubovo-hrabových lesov antropogénnych, ktoré v prípade mapy od Michalka et al. (1986) neboli identifikované.

Záver

Lesy predstavujú významný prvok krajiny pokrývky. V stredoeurópskych podmienkach sú na väčšine lesnej pôdy hospodárske lesy s rôznou intenzitou využívania. Pri hodnotení ich stavu a štruktúry má veľký význam porovnanie s konceptom PPV, ktorá prináša informácie použiteľné pri tvorbe rozhodnutí zameraných najmä na ochranu prírody, environmentálny manažment, environmentálne plánovanie a taktiež aj pre ďalší vedecký výskum krajiny. Hoci PPV predstavuje podľa viacerých autorov zastaraný prístup. Prezentovaná práca a jej metodický postup vedú k potvrdeniu skutočnosti, že aplikácia detailného terénneho vegetačného a geoeologického výskumu spojeného s odberom pôdnych vzoriek, následných laboratórnych rozborov, aplikáciou štatistických analýz, priestorového modelovania, moderných objektovo-orientovaných metód, prostredia GIS a najmodernejších klasifikačných postupov strojového učenia prináša nové, podrobné a v plánovacej praxi využiteľné informácie o vegetácii.

Literatúra

- BRAUN-BLANQUET, J. 1932: *Plant Sociology, the Study of Plant Communities*. New York (McGraw-Hill).
- BREIMAN, L. 1996: Bagging predictors. *Machine Learning*, 24, 123-140. DOI: <https://doi.org/10.1023/A:1018054314350>.
- BREIMAN, L. 2001: Random forests. *Machine Learning*, 45, 5-32. DOI: <https://doi.org/10.1023/A:1010933404324>.
- COHEN, J. 1960: A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20, 37-46. DOI: <https://doi.org/10.1177/001316446002000104>.
- CONRAD, O., BECHTEL, B., BOCK, M. et al. 2015: System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, *Geoscientific Model Development*, 8, 1991-2007. DOI: <https://doi.org/10.5194/gmd-8-1991-2015>.
- DEFINIENS 2009: *eCognition Developer 9 Reference Book, Version 9.0.1*. München (Definiens AG).
- DIVÍŠEK, J., CHYTRÝ, M. 2018: High-resolution and large-extent mapping of species richness using vegetation-plot databases: an example of Czech grasslands and forests. *Ecological Indicators*, 89, 840-851. DOI: <https://doi.org/10.1016/j.ecolind.2017.11.005>.
- DRAGUT, L., BLASCHKE, T. 2006: Automated classification of landform elements using object-based image analysis. *Geomorphology*, 81, 330-344. DOI: <https://doi.org/10.1016/j.geomorph.2006.04.013>.
- DRAGUT, L., CSILLIK, O., EISANK, C., TEIDE, D. 2014: Automated parameterisation for multi-scale image segmentation on multiple layers. *ISPRS Journal Photogrammetry and Remote Sensing*, 88, 119-127. DOI: <https://doi.org/10.1016/j.isprsjprs.2013.11.018>.
- ESRI 2017: *ArcGIS pro 2.0.0*. Redlands (Environmental Systems Research Institute).
- FABER, A. 1937: *Erläuterungen zum pflanzensoziologischen Kartenblatt des mittleren Neckar- und des Ammertalgebirges*. Stuttgart (Württembergische Forstdirektion und Württembergische Naturaliensammlung).
- FALŤAN, V. 2005: *Veľkomierkové mapovanie vegetácie a krajinej pokrývky*. Bratislava (Univerzita Komenského).
- FISCHER, H. S. 1990: Simulating the distribution of plant communities in an alpine landscape. *Coenoses*, 5, 37-43.
- FISCHER, H. S., WINTER, S., LOHBERGER, E., JEHL, H., FISCHER, A. 2013: Improving Transboundary Maps of Potential Natural Vegetation Using Statistical Modeling Based on Environmental Predictors. *Folia Geobotanica*, 48, 115-135. DOI: <https://doi.org/10.1007/s12224-012-9150-0>.
- FORE, S.R., HILL, M.J. 2017: Modeling the potential natural vegetation of Minnesota, USA. *Ecological Informatics*, 41, 116-132. DOI: <https://doi.org/10.1016/j.ecoinf.2017.07.006>.
- FRANKLIN, J. 2010: *Mapping species distributions: spatial inference and prediction*. Cambridge (Cambridge University Press).
- GAO, J. 2009: *Digital analysis of remotely sensed imagery*. New York (McGraw Hill).
- GILLIN, C. O., BAILEY, S. W., MCGUIRE, K. J., PRISLEY, P. S. 2015: Evaluation of Lidar-derived DEMs through Terrain Analysis and Field Comparison. *Photogrammetric Engineering & Remote Sensing*, 81, 387-396. DOI: <https://doi.org/10.14358/PERS.81.5.387>.
- GOUNARIDIS, D., APOSTOLOU, A., KOUKOULAS, S. 2015: Land cover of Greece, 2010: a semi-automated classification using random forests. *Journal of Maps*, 12, 1-8. DOI: <https://doi.org/10.1080/17445647.2015.1123656>.
- HALFMANN, J. 2000: *Biotopkartierung und Vegetationskartierung*. In Barsch, H., Billwitz, K., Bork, H. R. eds. *Arbeitsmethoden in Physiogeographie und Geoökologie*. Gotha (Justus Perthes), pp. 253-287.
- HEMSING, L.Ø., BRYN, A. 2012: Three methods for modelling potential natural vegetation (PNV) compared: A methodological case study from south-central Norway. *Norsk Geografisk Tidsskrift*, 66, 11-29. DOI: <https://doi.org/10.1080/00291951.2011.644321>.
- HENNKENS, S., SCHAMINÉE, J. 2001: Turboveg, a comprehensive database management system for vegetation data. *Journal of Vegetation Sciences*, 12, 589-591. DOI: <https://doi.org/10.2307/3237010>.

- HÖRSCH, B. 2003: Modelling the spatial distribution of montane and subalpine forests in the central Alps using digital elevation models. *Ecological Modelling*, 168, 267-282. DOI: [https://doi.org/10.1016/S0304-3800\(03\)00141-8](https://doi.org/10.1016/S0304-3800(03)00141-8).
- CHIARUCCI, A., ARAÚJO, M. B., DECOCQ, G., BEIERKUHNLEIN, C., FERNÁNDEZ-PALACIOS, J. M. 2010: The concept of potential natural vegetation: an epitaph? *Journal of Vegetation Science*, 21, 1172-1178. DOI: <https://doi.org/10.1111/j.1654-1103.2010.01218.x>.
- JANSKÁ, V., JIMÉNEZ-ALFARO, B., CHYTRÝ, M. et al. 2017: Palaeodistribution modelling of European vegetation types at the Last Glacial Maximum using modern analogues from Siberia: prospects and limitations. *Quaternary Science Reviews*, 159, 103-115. DOI: <https://doi.org/10.1016/j.quascirev.2017.01.011>.
- JAROLÍMEK, I., ŠÍBIK, J., HEGEDUŠOVÁ, et al. 2008: A list of vegetation units of Slovakia. In: JAROLÍMEK, I., ŠÍBIK, J. eds.: *Diagnostic, constant and dominant species of the higher vegetation units of Slovakia*. Bratislava (Veda), pp. 295-329.
- JÄGER, E.J. 1997: Allgemeine Vegetationsgeographie. In: Hendl, M., Liedtke, H. eds. *Lehrbuch der allgemeinen physischen Geographie*. Gotha (Justus Perthes), pp. 511-582.
- KUBALA-KUKUŠ, A., BANAŠ, D., BRAZIEWICZ, J. et al. 2015: X-ray spectrometry and X-ray microtomography techniques for soil and geological samples analysis. *Nuclear Instruments and Methods in Physics Research, Section B: Beam Interactions with Materials and Atoms*, 364, 85-92. DOI: <https://doi.org/10.1016/j.nimb.2015.07.136>.
- LIU, H., WANG, L., YANG, J. et al. 2009: Predictive modeling of the potential natural vegetation pattern in northeast China. *Ecological Research*, 24, 1313-1321. DOI: <https://doi.org/10.1007/s11284-009-0616-3>.
- LOIDI, J., DEL ARCO, M., PÉREZ DE PAZ, P. L. et al. 2010: Understanding properly the 'potential natural vegetation' concept. *Journal of Biogeography*, 37, 2209-2211. DOI: <https://doi.org/10.1111/j.1365-2699.2010.02302.x>.
- LOIDI, J., FERNÁNDEZ-GONZÁLEZ, F. 2012: Potential natural vegetation: Reburying or reboring? *Journal of Vegetation Science*, 23, 596-604. DOI: <https://doi.org/10.1111/j.1654-1103.2012.01387.x>.
- MALLINIS, G., KOUTSIAS, N., TSAKIRI-STRATI, M., KARTERIS, M. 2008: Object-based classification using Quickbird imagery for delineating forest vegetation polygons in Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63, 237-250. DOI: <https://doi.org/10.1016/j.isprsjprs.2007.08.007>.
- MICHALKO, J., BERTA, J., MAGIC, D. 1986: *Geobotanická mapa ČSSR, časť Slovenská socialistická republika*. Bratislava (Veda).
- MINÁR, J., BARKA, I., BONK, R. et al. 2001: *Geoekologický (komplexný fyzickogeografický) výskum a mapovanie vo veľkých mierkach*. Bratislava: Univerzita Komenského v Bratislave, Prírodovedecká fakulta (Geografika).
- MUCINA, L. 2010: Floristic-phytosociological approach, potential natural vegetation, and survival of prejudice. *Lazaroa*, 31, 173-182. DOI: https://doi.org/10.5209/rev_LAZA.2010.v31.13.
- NUSSBAUM, S., NIEMEYER, I., CANTY, M. 2006: SEaTH – A new tool for automated feature extraction in the context of object-based image analysis. In: Lang, S., Blaschke, T., Schöpfer, E. eds. *Proceedings of the 1st International Conference on Object-based Image Analysis (OBIA 2006)*. Austria (Salzburg University).
- OLIVERO, J., MÁRQUEZ, A. L., REAL, R. 2013: Integrating fuzzy logic and statistics to improve the reliable delimitation of biogeographic regions and transition zones. *Systematic Biology*, 62, 1-21. DOI: <https://doi.org/10.1093/sysbio/sys061>.
- ROLEČEK, J., TICHÝ, L., ZELENÝ, D., CHYTRÝ, M. 2009: Modified TWINSpan classification in which hierarchy respects cluster heterogeneity. *Journal of Vegetation Science*, 20, 1-7. DOI: <https://doi.org/10.1111/j.1654-1103.2009.01062.x>.
- ROMPORTL, D., CHUMAN, T., LIPSKÝ, Z. 2013: Landscape typology of Czechia. *Geografie*, 118, 16-39.
- RUŽICKOVÁ, H. et al. (eds.) 1996: *Biotopy Slovenska*. Bratislava (Ústav krajiny ekológie SAV).
- SOMODI, I., MOLNÁR, Z., CZÚCZ, B. et al. 2017: Implementation and application of multiple potential natural vegetation models - a case study of Hungary. *Journal of Vegetation Science*, 28, 1-10. DOI: <https://doi.org/10.1111/jvs.12564>.

- SOMODI, I., MOLNÁR, Z., EWALD, J. 2012: Towards a more transparent use of the potential natural vegetation concept - an answer to Chiarucci et al. *Journal of Vegetation Science*, 23, 590-595. DOI: <https://doi.org/10.1111/j.1654-1103.2011.01378.x>.
- SUN, X., ROSIN, P. L., MARTIN, R. R., LANGBEIN, F. C. 2007: Fast and Effective Feature-Preserving Mesh Denoising. *IEEE Transactions on Visualization and Computer Graphics*, 13, 925-938. DOI: <https://doi.org/10.1109/TVCG.2007.1065>.
- SZYMURA, T. H., SZYMURA, M., MACIOŁ, A. 2014: Bioindication with Ellenberg's indicator values: A comparison with measured parameters in Central European oak forests. *Ecological Indicators*, 46, 495-503. DOI: <https://doi.org/10.1016/j.ecolind.2014.07.013>.
- TICHÝ, L. 2002: JUICE software for vegetation classification. *Journal of Vegetation Science*, 13, 451-453. DOI: <https://doi.org/10.1111/j.1654-1103.2002.tb02069.x>.
- TIVY, J. 1993: *Biogeography*. Eidinburg (Addison Wesley Longman).
- TÜXEN, R. 1956: Die heutige potentielle natürliche Vegetation als Gegenstand der Vegetationskartierung. *Angew Pflanzensoziol (Stolzenau)*, 13, 5-42.
- WALKER, E., MONESTIEZ, P., GOMEZ, C., LAGACHERIE, P. 2017: Combining measured sites, soilscape map and soil sensing for mapping soil properties of a region. *Geoderma*, 300, 64-73. DOI: <https://doi.org/10.1016/j.geoderma.2016.12.011>.
- ZHANG, Z., VAN COILLIE, F., OU, X., DE WULF, R. 2014: Integration of satellite imagery, topography and human disturbance factors based on canonical correspondence analysis ordination for mountain vegetation mapping: A case study in Yunnan, China. *Remote Sensing*, 6, 1026-1056. DOI: <https://doi.org/10.3390/rs6021026>.

Pod'akovanie: Publikácia vznikla v rámci riešenia projektu APVV-15-0597 „Využitie geoeologických podkladov v rámci zavádzania precízneho poľnohospodárstva“, VEGA 1/0421/16 „Analýza zmien krajinej pokrývky v kontexte environmentálnych hybných síl“ a VEGA 1/0540/16 „Sociálne, ekonomické a environmentálne determinanty rozvoja a transformácie regiónov: regionálnogeografický prístup“.

Adresy autorov

Mgr. Marián Gábor, PhD.
Národné lesnícke centrum, Ústav lesných zdrojov a informatiky,
Odbor diaľkového prieskumu Zeme,
Sokolská 2, 960 01 Zvolen
Slovensko
gabor9@uniba.sk

RNDr. Lukáš Karlík, PhD.
Katedra regionálnej geografie, ochrany a plánovania krajiny
Prírodovedecká fakulta, univerzita Komenského,
Mlynská dolina, Ilkovičova 6, 842 15 Bratislava
Slovensko
karlik3@uniba.sk

RNDr. Igor Matečný PhD.
Katedra fyzickej geografie a geoekológie,
Prírodovedecká fakulta, univerzita Komenského,
Mlynská dolina, Ilkovičova 6, 842 15 Bratislava
Slovensko
igor.matecny@uniba.sk

doc. RNDr. Vladimír Faltán PhD.
Katedra fyzickej geografie a geoekológie,
Prírodovedecká fakulta, univerzita Komenského,
Mlynská dolina, Ilkovičova 6, 842 15, Bratislava
Slovensko
vladimir.faltan@uniba.sk