

HODNOTENIE METÓD A DÁT DPZ PRE ÚČELY KLASIFIKÁCIE KRAJINNEJ POKRÝVKY NA PRÍKLADE BÝVALÝCH VOJENSKÝCH OBVODOV BRDY A RALSKO

Daniel PALUBA, Přemysl ŠTYCH, Josef LAŠTOVIČKA

Evaluation of remote sensing methods and data for land cover classification: case studies of former military training areas Brdy and Ralsko

Abstract: Taking advantage of Earth Observation data for monitoring land cover has attracted the attention of a broad spectrum of researchers and end-users in recent decades. The main reason of increased interest in Earth Observation can be found mainly in open data of Landsat and Sentinel archive. The main objective of this study is to evaluate the accuracy of the classification algorithms Maximum Likelihood (ML) and Support Vector Machine (SVM) using Landsat 8 and Sentinel-2 data in the case studies of the former military training areas Brdy and Ralsko, which have undergone a very specific land cover development. The study evaluates the land cover in both case studies in 2016 and based on the obtained results discussing a usefulness of the selected data and methods. The results of the land cover classification achieved satisfactory accuracy – the overall accuracy was higher than 85%. Based on the expectation, the results of accuracy based on SVM algorithm are higher than results obtained by ML algorithm. The highest accuracy has reached in the land cover classes of water bodies and coniferous forests, on the contrary, the lowest accuracy in built-up areas, sparse vegetation and bare soil.

Keywords: Earth Observation, Support Vector Machine, Maximum Likelihood, Czechia, Sentinel-2, Landsat 8

Úvod

V súčasnosti máme k dispozícii širokú škálu klasifikačných algoritmov, ktoré je možné využiť k hodnoteniu krajiny pokrývky. Klasifikačný algoritmus sa volí na základe viacerých kritérií, napr. podľa charakteristiky krajinného krytu skúmaného územia, vstupných dát, dostupnosti a kvality referenčných dát a skúseností analytika. Jeden z najvyužívanejších algoritmov je Maximum Likelihood (ML) [1], [15], [20], a to najmä vďaka robustnosti a ľahkému prístupu v takmer každom softvéri na spracovanie obrazu [14]. Canaz, Aliefendioğlu a Tanrıvermiş [4] ho použili vo svojej štúdií s argumentom, že dosahuje najvyššie presnosti spomedzi klasifikátorov. Support Vector Machine (SVM) od začiatku 21. storočia predstavuje alternatívu s lepšou presnosťou klasifikácie v porovnaní s dovtedy hojne využívanými algoritmi [20]. ML sa začal využívať hlavne na porovnanie s ostatnými algoritmi. Khatami, Mountrakis a Stehman [11] vytvorili meta-analýzu 266 článkov, v ktorej porovnávali klasifikačné algoritmy a manipuláciu so vstupnými dátami a zistili, že takmer vo všetkých štúdiách SVM prekonal ostatné algoritmy. Napriek dokázanej vyššej presnosti klasifikačného algoritmu SVM sa Mihai et al. [15] pokúsili kvantifikovať zmenu lesnej pokrývky pohoria Iezer v Rumunsku v kontexte intenzifikácie odlesňovania na základe klasifikácie dát diaľkového prieskumu Zeme (DPZ) algoritmom ML. Hlavná výskumná otázka smerovala k dynamike zmeny lesa v sledovanom období a k vhodnosti využitia dát s priestorovým rozlíšením 30 m. Autori dospeli k záveru, že „analýza detekcie zmeny pri priestorovom rozlíšení 30 m vyhovuje požiadavkám na mapovanie a hodnotenie zmien lesných porastov na lokálnej úrovni“ [15, s. 2173]. Rujoiu-Mare et al. [21] s algoritmom ML dosiahli presnosť 98,65 %, a to hlavne kvôli vhodnému výberu algoritmu pre takmer homogénne územie podkarpatskej oblasti.

Bc. Daniel PALUBA, doc. RNDr. Přemysl ŠTYCH, Ph.D., Mgr. Josef LAŠTOVIČKA, Katedra aplikovanej geoinformatiky a kartografie, Přírodovědecká fakulta, Univerzita Karlova, Albertov 6, 128 43, Praha 2, Česko, e-mail: palubad@natur.cuni.cz, stych@natur.cuni.cz, pepa.lastovicka@gmail.com

Existuje veľký počet štúdií, ktoré sa zaoberajú porovnávaním jednotlivých klasifikačných algoritmov navzájom. Sanchez-Hernandez et al. [22] porovnávali výkon klasifikátorov SVM a ML na príklade mapovania špecifických stanovišť použitím dát Landsat 5 ETM+ v okrese North Norfolk vo Veľkej Británii. Pri použití SVM sa ich výsledky zlepšili o takmer 28 percentuálnych bodov oproti výsledkom získaných algoritmom ML. Karan a Samadder [10] zistili, že algoritmus SVM má o 3 až 6 percentuálnych bodov vyššiu presnosť klasifikácie snímok Landsat 5 a Landsat 8, resp. SVM prekonal ML hlavne pri riešení ťažkej výzvy – klasifikácii prvkov, ktoré majú podobnú odrazivosť. Topaloğlu, Sertel a Musaoğlu [24] porovnávali presnosť klasifikácie krajiny pokrývajúcej Istanbul z dát Sentinel-2 a Landsat 8 s využitím oboch klasifikačných metód – ML a SVM s cieľom porovnať výslednú presnosť. Došli k záveru, že klasifikácia algoritmom SVM je presnejšia pre dáta Landsat i Sentinel, vyššiu presnosť dosiahli klasifikácie na dátach Sentinel-2. To sa dá vysvetliť aj tým, že sledované územia mali heterogénnejšie dáta, ktoré SVM lepšie spracúva.

Hlavným cieľom našej štúdie je porovnať presnosť v súčasnosti najznámejších klasifikačných algoritmov (ML a SVM) na dvoch typoch vstupných dát (Landsat 8 a Sentinel-2) s rozličným spektrálnym a priestorovým rozlíšením na územiach zaniknutých vojenských obvodov (VO) Brdy a Ralsko. Predpokladalo sa, že algoritmus SVM a zároveň klasifikácie snímok Sentinel-2 budú mať vyššiu presnosť než algoritmus ML, resp. dáta z Landsat 8. S novou ponukou dát misie Sentinel a dynamickým rozvojom klasifikačných metód ide o tému vysoko relevantnú, keďže ukazuje na silné a slabé stránky používaných dát Sentinel-2 a Landsat 8 a vzájomne hodnotí dosiahnuté presnosti často používaných klasifikátorov.

1. Teoretický rámec

Predpokladom úspešnej klasifikácie krajiny pomocou dát DPZ je vhodný návrh procedúr spracovania satelitnej snímky [14]. Proces klasifikácie je komplexný mechanizmus, v ktorom sa majú brať do úvahy viaceré faktory od výberu dát na klasifikáciu, referenčných dát, predspracovania obrazu, stanovenia klasifikačných tried, identifikácie a vyznačenia tréningových plôch, výberu vhodného klasifikačného algoritmu až po post-klasifikačné úpravy a hodnotenie správnosti, resp. presnosti klasifikácie [11].

1.1 Vstupné dáta pre klasifikáciu

Jedným z najdôležitejších krokov klasifikácie dát DPZ je vhodný výber vstupných dát. Výber je ovplyvnený rôznymi faktormi, ktorými sú napr. potreby používateľa, mierka a charakteristika skúmaného územia, dostupnosť rozličných snímok a ich charakteristika, časové a finančné náklady s nimi spojené a pracovné skúsenosti analytika s vybraným typom snímky. Za najdôležitejšie sa považujú rozlíšenie snímky (GSD – efektívne rozlíšenie na zemskom povrchu) a potreby používateľa [14]. Pri výbere typu dát pre určité aplikácie treba dbať aj na charakteristiku vstupných dát. V našom prípade to bola aj ich voľná dostupnosť, preto sme vybrali dáta Sentinel-2 a Landsat 8.

1.2 Tréningové plochy

Ďalším nevyhnutným krokom kontrolovanej klasifikácie je vytvorenie tréningových plôch [10]. Tréningové dáta sa najčastejšie zbierajú z pozemných meraní alebo sa vyznačujú nad vrstvou leteckých alebo družicových snímok s vysokým rozlíšením alebo pomocou iných referenčných dát (napr. [15], [18]). Problémom môžu byť napr. nevyvážené tréningové dáta, keď počet tréningových plôch (alebo pixelov) určitej klasifikačnej triedy je menší alebo väčší než v ostatných triedach. Klasifikovanie takýchto dát môže byť problematické pre niektoré klasifikačné algoritmy z hľadiska výslednej presnosti [28].

1.3 Opis použitých klasifikačných algoritmov

Maximum Likelihood je dobre známy algoritmus kontrolovanej klasifikácie. Počíta pravdepodobnosť, s ktorou sa dá daný pixel zaradiť do určitej triedy krajiny pokrývajúcej a následne ho priradí k triede s najvyššou hodnotou, resp. nepriradí k žiadnej, keď hodnota pravdepodobnosti je nižšia ako vopred stanovený prah (threshold) [1]. ML je závislý na pravdepodobnosti rozdelenia tried prvkov. Výhodou je, že zohľadňuje variačný koeficient v rozdeleniach tried a pre normálne rozdelenie má ML niekedy lepšie výsledky než ostatné parametrické klasifikátory (napr. [21]). Pre dáta, ktoré nemajú normálne rozdelenie, môže produkovať neuspokojivé výsledky.

Support Vector Machine je neparametrický kontrolovaný klasifikátor s cieľom nájsť nadrovinu (hyperplane), ktorá priestor príznačkov optimálne rozdelí tak, že tréningové plochy patriace do odlišných tried ležia v opačných polpriestoroch [5]. Významnou prácou aplikujúcou metódu SVM pri klasifikácii dát DPZ je Pal a Mather [20]. Mountrakis, Im a Ogole [17] sa zamerali na súčasné štúdie publikované v 8 hlavných časopisoch o problematike DPZ (spolu 108 štúdií) zaoberajúce sa implementáciou algoritmu SVM. Zistili, že SVM, na rozdiel od ML, nie je senzitívny na veľkosť tréningových plôch a potvrdilo sa, že SVM pracuje dobre aj s tréningovými plochami s limitovanou kvalitou i kvantitou, avšak na druhej strane treba vhodne nastaviť parametre klasifikátora.

1.4 Hodnotenie presnosti

Posledným dôležitým krokom klasifikačného procesu je hodnotenie výsledkov klasifikácie. Na hodnotenie presnosti klasifikácie sa najbežnejšie používa metóda priestorového porovnania výslednej klasifikácie, ktorá dáta s nižším priestorovým rozlíšením porovnáva s dátami s vyšším priestorovým rozlíšením. Cieľom je kvantifikovať celkovú presnosť získaného výsledku a aj presnosť každej klasifikačnej triedy. Existuje veľké množstvo metód a techník na hodnotenie presnosti klasifikácie, najrozšírenejšie sú: chybové matice, výpočet celkovej presnosti a kappa indexu (napr. [1], [8], [15], [18], [19], [21], [24]).

2. Záujmové územia

Záujmové územia v tejto štúdií tvorili zaniknuté VO Brdy a Ralsko. Bývalý VO Brdy sa nachádzal v juhozápadnej časti Českej republiky (ČR), konkrétne na hranici Plzeňského kraja a Stredočeského kraja (obr. 1) s celkovou výmerou 26 009 ha. Z nej sa pre vojenské účely využívalo len 3 217 ha v tzv. vojenskom výcvikom priestore (VVP) Jince. Ostatné plochy boli hospodársky využívané Vojenskými lesy a statky (VLS) ČR [16]. VO Brdy bol zriadený v roku 1949 a zanikol 1. januára 2016. Na celej ploche VO vznikla Chránená krajinná oblasť Brdy. Časť VO sa bude naďalej využívať pre výcvik – vzniklo posádkové cvičisko Jince s rozlohou 560 ha [16].

VO Ralsko sa nachádzal v severovýchodnej časti ČR, konkrétne na hranici Stredočeského kraja a Libereckého kraja (obr. 1). Z celkovej výmery 24 942 ha bolo na vojenský výcvik vo VVP Mimoň určených 5 522 ha, teda vyše 22 % plochy [23]. Na väčšine vojensky nevyužitých pozemkoch VO Ralsko pôsobili, a aj v súčasnosti pôsobia, VLS ČR. VVP Mimoň vznikol v roku 1950 a v roku 1991 bol zrušený.

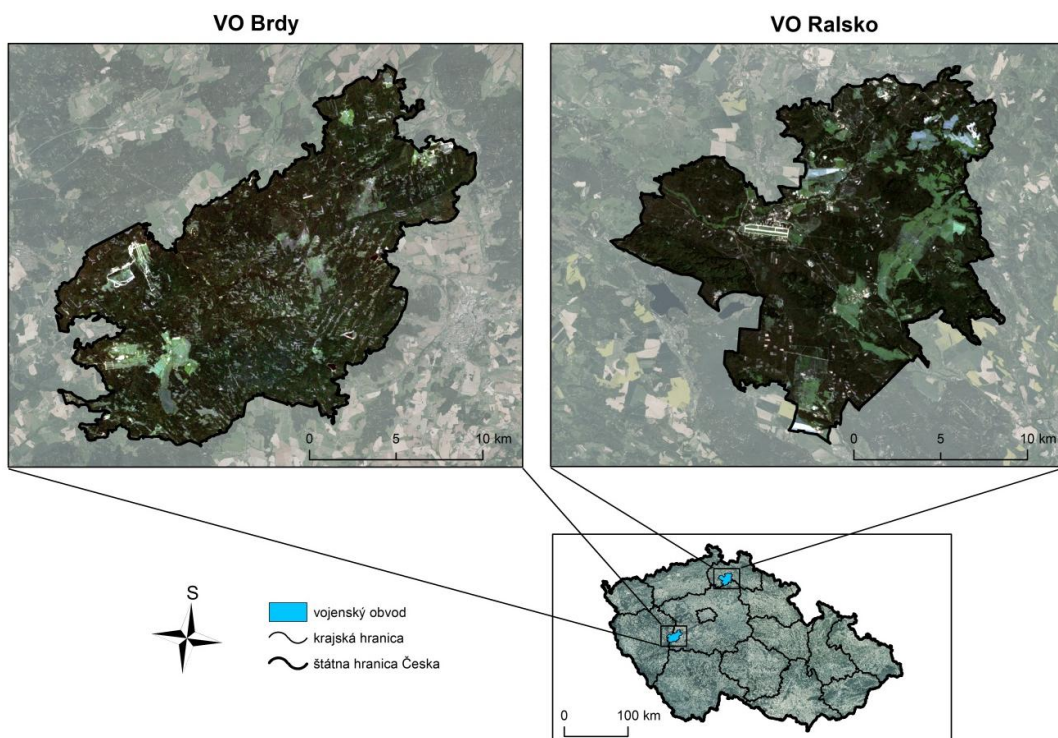
3. Použité dáta a metodika

3.1 Satelitné snímky

Na spracovanie klasifikácie krajiny pokrývky v záujmových územiach majú voľne dostupné satelitné snímky družicových misií Landsat a Sentinel vyhovujúce temporálne a priestorové rozlíšenie. Snímky misie Landsat, poskytované US Geological Survey (USGS), sme získali z portálu EarthExplorer a dáta Sentinel, poskytované European Space Agency (ESA), z portálu Copernicus Open Access Hub. Pre záujmové územia boli vybrané bezoblačné snímky z družíc Sentinel-2 a Landsat 8 snímané v rovnaký deň, 27. 8. 2016.

Landsat 8

Z misie Landsat sme využili snímky senzoru Landsat 8 OLI/TIRS, a to dáta typu Level-2 SR (Surface Reflectance), ktoré sú už pripravené na použitie, napr. na monitorovanie krajiny pokrývky. Ide o dáta s blízkym odhadom spektrálnej odrazivosti zemského povrchu (Bottom of Atmosphere – BOA), akoby snímané priamo nad zemským povrchom s absenciou atmosférického rozptylu alebo absorpcie, aj odstránením rušivých vplyvov osvetlenia a geometrie [26]. Multispektrálne dáta Landsat 8 sú snímané v 11 spektrálnych pásmach senzormi Operational Land Imager (OLI) a Thermal Infrared Sensor (TIRS) s priestorovým rozlíšením 30 a 100 m (tab. 1). Dátová sada Level-2 SR obsahuje len 7 pásiem. Za 1 deň sníma Landsat 8 vyše 400 snímok so šírkou scény 185 km, temporálne rozlíšenie je 16 dní a rádiometrické 12 bitov [13].



Obr. 1 Poloha záujmových území v rámci ČR
(datové zdroje: ArcČR 500 3.2, ArcČR 500 3.3, WMS Ortofoto ČÚZK, 2018)

Sentinel-2

Na základe ESA [7] je Sentinel-2 širokopásmová, multispektrálna snímkovacia misia s vysokým rozlíšením podporujúca Copernicus Land Monitoring aplikácie, zahŕňa monitorovanie vegetácie, pôdneho krytu, vodných plôch a tokov. Od roku 2017 v misii Sentinel-2 pracujú súčasne 2 identické satelity posunuté o 180°, umiestnené na polárnej, slnečne-synchronnej obežnej dráhe vo výške 786 km, kvôli čomu sa temporálne rozlíšenie dát znížilo z 10 na 5 dní. Snímky sú snímané v 13 spektrálnych pásmach, z toho 4 majú 10 metrové priestorové rozlíšenie, 6 pásiem s 20 metrovým a 3 pásma so 60 metrovým rozlíšením (tab. 1). Šírka jedného pásma predstavuje 290 km. Radiometrické rozlíšenie majú rovnaké ako Landsat 8 dáta – 12 bitové. Z portálu Copernicus Open Access Hub boli získané snímky Sentinel-2 vo formáte Level 1C TOA (Top of atmosphere), ktoré bolo treba následne upraviť na formát Level 2A SR na porovnanie so snímkami Landsat 8.

3.2 Referenčné dáta

Na identifikáciu trénovacích plôch a následnú kontrolu správnosti klasifikácie sme použili letecké snímky. Konkrétne ortofotomapa od spoločnosti TopGIS poskytnutá na vyžiadanie vo forme služby WMS. Jej priestorové rozlíšenie bolo 12,5 cm, zdrojové snímky pre západnú časť ČR boli snímané v roku 2016, konkrétne medzi 28. a 31. augustom v oblasti VO Brdy (rozdiel medzi satelitnými snímkami a ortofotomapou maximálne 4 dni) a v oblasti VO Ralsko 24. júna (rozdiel približne 2 mesiace) a malá časť 31. augusta [25].

Pri identifikácii trénovacích plôch a následne aj kontrole presnosti klasifikácie v oblasti VO Ralsko a rozhodovaní sa medzi ornou pôdou a trvalým trávny porastom vo funkcii podporných referenčných dát sme zvolili Verejný registr pôdy LPIS, ktorého online databáza obsahuje nielen súčasný stav a charakteristiku jednotlivých hospodársky využívaných pôd, ale aj dáta z predošlých registrovaných období.

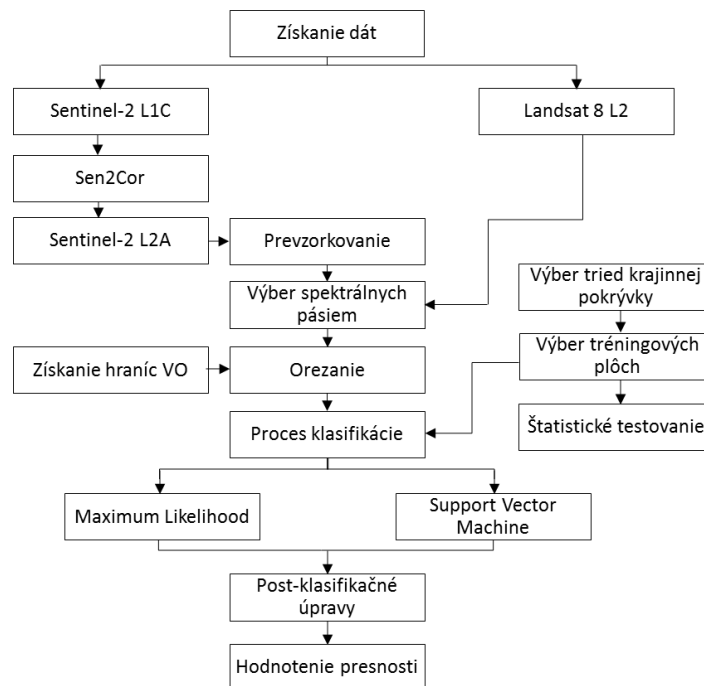
Tab. 1 Porovnanie spektrálnych pásiem dát Sentinel-2 a Landsat 8

Spektrálne pásmo	Rozsah vlnovej dĺžky (µm)	Priestorové rozlíšenie (m)	Spektrálne pásmo	Rozsah vlnovej dĺžky (µm)	Priestorové rozlíšenie (m)
Sentinel-2			Landsat 8		
1 – Coastal /Aerosol	0,43–0,46	60	*1 Coastal/Aerosol	0,43–0,45	30
*2 – Blue	0,44–0,54	10	*2 Blue	0,45–0,51	30
*3 – Green	0,54–0,58	10	*3 Green	0,53–0,59	30
*4 – Red	0,65–0,68	10	*4 Red	0,64–0,67	30
*5 – NIR 2	0,69–0,71	20	–	–	–
*6 – NIR 3	0,73–0,75	20	–	–	–
*7 – NIR 4	0,77–0,80	20	–	–	–
*8 – NIR 1)	0,77–0,91	10	–	–	–
8a – NIR 5	0,85–0,88	20	*5 Near Infrared (NIR)	0,85–0,88	30
9 – Water vapour	0,93–0,96	60	–	–	–
10 – Cirrus	1,34–1,41	60	9 Cirrus	1,36–1,38	30
*11 – SWIR 1	1,54–1,68	20	*6 SWIR 1	1,57–1,65	30
*12 – SWIR 2	2,08–2,32	20	*7 SWIR 2	2,11–2,29	30
–	–	–	8 Panchromatic	0,50–0,68	15
–	–	–	10 Thermal Infrared (TIRS) 1	10,60–11,19	100
–	–	–	11 Thermal Infrared (TIRS) 2	11,50–12,51	100

Zdroje dát: [6], [12], [27], * spektrálne pásma použité v klasifikácii

3.3 Metodika práce

Metodiku práce ilustruje obr. 2. Začala získaním potrebných satelitných snímok z portálov EarthExplorer a Copernicus Open Access Hub, ortofotomapy TopGIS a hraníc bývalých VO. Nasledovalo predspracovanie satelitných snímok v softvéroch ENVI a SNAP, atmosférické korekcie dát Sentinel-2 pomocou nástroja Sen2Cor, čím sme získali dáta Sentinel-2 Level 2A BOA, prevzorkovali sme dáta na 10 metrovým priestorovým rozlíšením, vybrali vhodné spektrálne pásma (tab. 1) a snímky orezali hranicami skúmaných území. Pred samotným procesom klasifikácie bolo treba stanoviť, ktoré triedy krajiny pokrývky chceme získať klasifikáciou. Triedy sme prevzali z nomenklatúry CORINE Land Cover na tretej hierarchickej úrovni [3], nápomocná bola aj nomenklatúra EAGLE [2]. Následne sme vytvorili modifikovanú legendu, kde sme brali do úvahy netradičné, ale pre našu analýzu relevantné triedy, napr. sukcesívne porasty. Vybrali sme 8 tried (tab. 2): vodné plochy, listnaté lesy, ihličnaté lesy, zastavané plochy, trávnatý porast, riedku vegetáciu, plochy bez vegetácie a ornú pôdu (len v prípade VO Ralsko). Po stanovení vhodných tried sme tréningové plochy identifikovali a následne vyznačili nad vrstvou satelitných snímok, tiež pomocou získaných ortofotomáp. Pri vyznačovaní sme dbali na to, aby jednotlivé tréningové plochy nezasahovali do okolitých pixelov, teda obsahovali len pixely jednej triedy. Minimálnu veľkosť sme stanovili na 5 pixelov (pre Landsat 8 dáta) so snahou zachovať vyváženosť tréningových plôch (cca 220 pixelov/trieda pre Landsat 8 a 1 400 pixelov/trieda pre Sentinel-2) s tým, že museli byť rovnaké pre Landsat 8 i Sentinel-2 dáta. Tréningové plochy mohli vstupovať do klasifikácie až po štatistickej validácii, teda kontrole normálneho rozdelenia pre jednotlivé triedy a testovaní oddeliteľnosti tried na základe metódy Jeffries-Matusita vzdialenosti a transformovaných divergencií (JM). Po kontrole vhodnosti tréningových plôch sme klasifikovali krajinnú pokrývku pomocou algoritmov ML a SVM v softvéri ENVI 5.1 a post-klasifikačnými úpravami v softvéri ArcMap. V post-klasifikačných úpravách sme agregovali všetky klasifikované plochy menšie ako 0,25 ha, resp. 0,5 ha (minimálna mapovacia jednotka) pre dáta Sentinel-2, resp. Landsat 8. V algoritme SVM sme použili polynomické jadro 6. stupňa s hodnotami 0,125 pre parameter C a 100 pre γ . Aby sa dali výsledky klasifikácie porovnať, bola potreba vyhodnotiť jej presnosť. Vytvorili sme preto chybové matice, vypočítali celkovú, používateľskú a spracovateľskú presnosť, Kappa koeficient s následným vypočítaním podielov plôch jednotlivých tried krajiny pokrývky.



Obr. 2 Metodika práce

Tab. 2 Charakteristika klasifikačných tried

Klasifikačné triedy	CLC/EAGLE ekvivalent	Opis triedy
vodné plochy	5.2.1. vodné plochy	jazerá a vodné nádrže vo vnútrozemí
listnaté lesy	3.1.1. listnaté lesy	územia aspoň s 30% pokrytím korunami listnatých lesov*
ihličnaté lesy	3.1.2. ihličnaté lesy	územia aspoň s 30% pokrytím korunami ihličnatých lesov*
zastavané plochy	1.1.1. súvislá zástavba 1.1.2. nesúvislá zástavba 1.2.4. areály letísk	súvislý a nesúvislý typ zástavby, z dopravnej infraštruktúry to boli len areály letísk
trávnaté porasty	2.3.1. lúky a pasienky 3.2.1. prirodzené lúky	oblasti hustého pokrytia trávnatým porastom, ktoré sú poľnohospodársky využívané na kosenie a pastvu dobytká alebo areály prirodzených trávnych porastov s rozptýlenými kríkmi
orná pôda	2.1.1. nezavlažovaná orná pôda	všetky poľnohospodárske pôdy, na ktorých sa pestovali obilniny, strukoviny, priemyslové plodiny, okopaniny a krmivá
riedka vegetácia	3.2.2. vresoviská a slatiny 3.2.4. prechodné lesokroviny 3.3.3. areály s riedkou vegetáciou	sukcesívna vegetácia prítomná v miestach prechodu novo vznikajúceho lesa z trávnatého porastu, hlavne v miestach nevyužívaných vojenských priestorov, v oblastiach vyťaženého lesa a na miestach významných vresovísk a krovísk na územiach bývalých dopadových plôch; do tejto triedy spadajú aj plochy lesných škôlok a mladých porastov charakteristické riedkym zastúpením drevín, resp. výskytom drevín nízkej výšky
bez vegetácie	**EAGLE: 1.2.4. holé pôdy	dopadové plochy a plochy strelníc pokryté holou pôdou bez vegetácie (zastúpenie vegetácie nižšie ako 10 %), resp. miesta po ťažbe stromov

Zdroj: [2] a [3], * v prípade zmiešaných lesov sa o zaradení do určitej triedy rozhodovalo na základe prevažujúceho zastúpenia dreviny, ** trieda odpovedá triede 1.2.4 holé pôdy z nomenklatúry EAGLE

4. Výsledky

Všetky klasifikácie krajiny pokrývky dosiahli celkovú presnosť vyššiu ako 85 %, čo sa dá považovať za veľmi dobrý výsledok (tab. 3). Na základe predpokladov a v úvode spomenutých výskumov sa očakávala vyššia presnosť klasifikácie algoritmom SVM oproti ML. Tento predpoklad sa naplnil, keďže vo VO Ralsko sme algoritmom SVM dosiahli vyššie presnosti oproti ML (o 5,25 percentuálneho bodu pre dáta Landsat 8, pri použití dát Sentinel-2 o 0,5 percentuálneho bodu). Pri použití dvoch typov dát s rozličným spektrálnym a priestorovým rozlíšením sme predpokladali vyššie presnosti klasifikácie pri dátach Sentinel-2 s vyšším priestorovým (10 m) a spektrálnym (9 vstupných pásiem) rozlíšením oproti dátam Landsat 8 (30 m a 6 pásiem). Zistili sme, že použitím rozličných vstupných dát a zároveň rovnakého algoritmu sa výsledky klasifikácie na území VO Brdy menia len nevýznamne. Naopak, na území VO Ralsko pri použití algoritmu SVM nad oboma typmi dát sa prejavil významný rozdiel (o 3,75 percentuálneho bodu v prospech dát Landsat 8), teda sa náš predpoklad nepotvrdil. Aj keď celkové presnosti dosiahnuté v klasifikáciách sú dostatočne vysoké, pri skúmaní presností jednotlivých klasifikačných tried treba poznamenať, že niektoré triedy dosahujú nižšiu presnosť.

Tab. 3 Presnosť klasifikácie v % nad dátami Landsat 8 a Sentinel-2 algoritmi ML a SVM na územiach VO Brdy a Ralsko

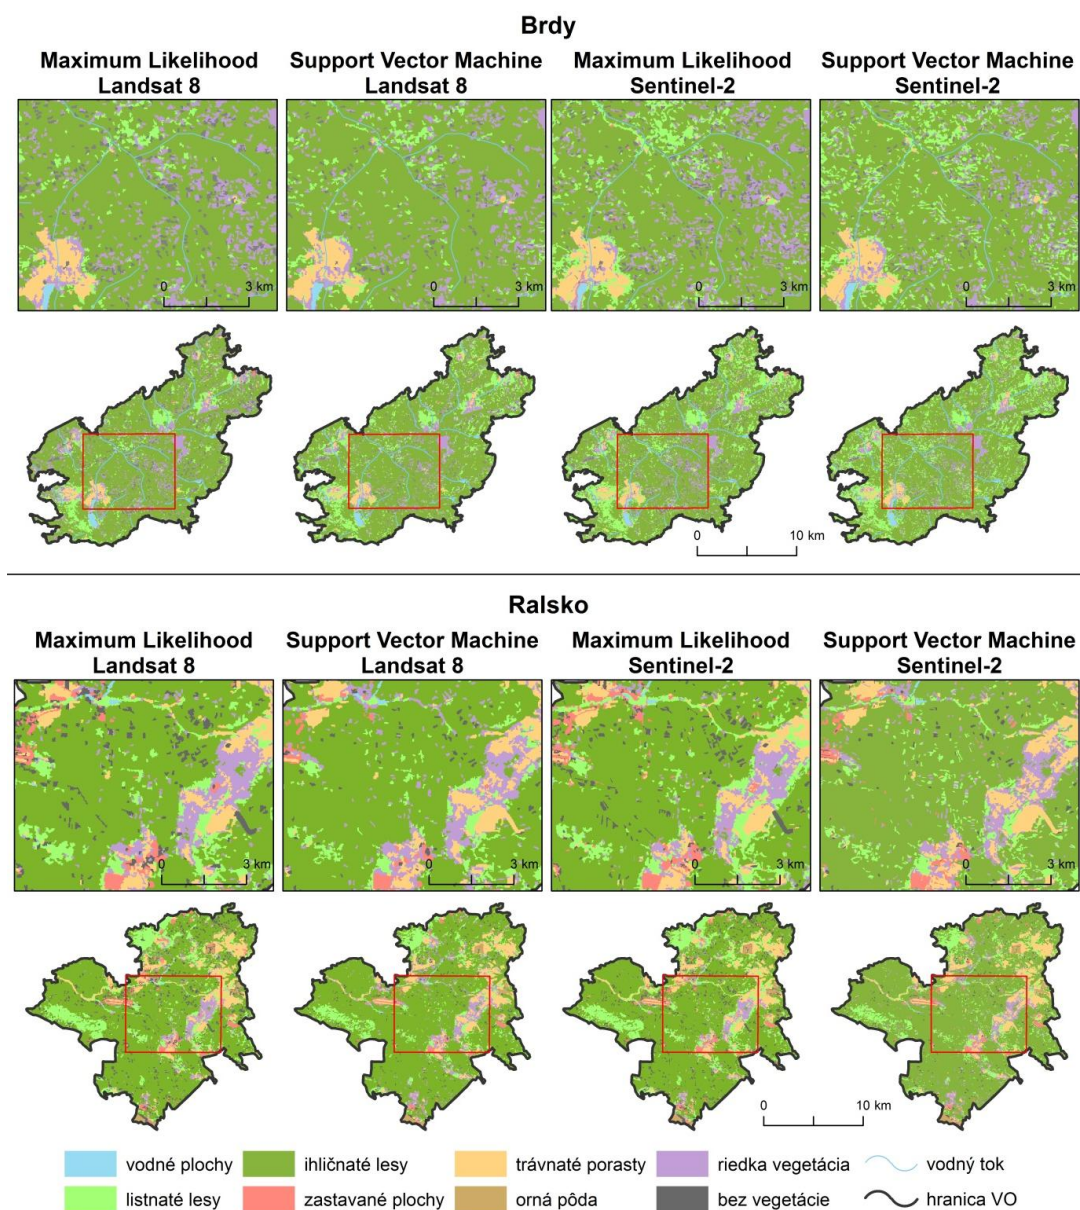
Územie	Vstupné dáta a algoritmy			
	Landsat 8		Sentinel-2	
	ML	SVM	ML	SVM
VO Brdy	88,86	92,57	88,29	93,43
VO Ralsko	86,00	91,25	87,00	87,50

Pri hodnotení výsledkov porovnaním jednotlivých tried krajiny pokrývky sa na území VO Ralsko prejavili podobnosti výsledkov použitím rovnakého algoritmu (ML aj SVM) nad oboma typmi dát, a to v celkovej presnosti (tab. 3), používateľských presnostiach (príloha 1 až 4), aj v percentuálnych zastúpeniach jednotlivých tried krajiny pokrývky (tab. 4).

Tab. 4 Podiel jednotlivých tried krajiny pokrývky v %

Trieda krajiny pokrývky	VO Brdy				VO Ralsko			
	Landsat 8		Sentinel-2		Landsat 8		Sentinel-2	
	ML	SVM	ML	SVM	ML	SVM	ML	SVM
vodné plochy	0,62	0,62	0,52	0,61	0,19	0,18	0,16	0,16
listnaté lesy	9,15	14,99	20,18	20,90	12,76	9,34	13,60	9,72
ihličnaté lesy	69,76	69,67	62,93	64,10	64,32	69,92	64,23	71,02
zastavané plochy	0,20	0,08	0,44	0,07	2,91	1,55	3,32	1,83
trávnatý porast	2,64	2,51	2,58	2,56	8,70	8,42	8,59	8,98
orná pôda	–	–	–	–	0,71	0,94	0,73	0,93
riedka vegetácia	13,13	10,30	9,48	9,51	4,84	7,93	4,70	5,92
bez vegetácie	4,50	1,83	3,87	2,25	5,57	1,71	4,67	1,44

V používateľských presnostiach použitím algoritmu ML bol rozdiel maximálne 4 percentuálne body, (len v prípade listnatých lesov 6 percentuálnych bodov). Podobnosť je zrejماً aj z vizuálneho výstupu klasifikácie krajiny pokrývky (obr. 3), konkrétne v oblastiach listnatých lesov Hradčanských bučín a Hradčanských stěn v západnej časti VO, v okolí vrchov Velká Buková a Malá Buková približne v strede VO a v oblasti bývalej ťažby uránu, na juh od obce Stráž pod Ralskem, v severozápadnej časti VO. Badateľ aj nižšie zastúpenie plôch bez vegetácie vytvorených algoritmom ML v oblasti bývalého vojenského cvičiska Židlov a zároveň vyššie zastúpenie plôch bez vegetácie nerovnomerne rozmiestnené po celom území VO. Len klasifikácia vodných plôch má veľmi podobné výsledky s použitím rovnakých dát a rozličných algoritmov.



Obr. 3 Výstupy klasifikácie krajinej pokrývky VO Ralsko v roku 2016 zo snímok Landsat 8 a Sentinel-2 algoritmi Maximum Likelihood a Support Vector Machine

Na území VO Brdy sa tak výrazný trend podobnosti neprejavil, avšak podobnosti sú aj v tomto prípade, napr. použitím jedného typu dát sú veľmi podobné podiely plôch listnatých a ihličnatých lesov (tab. 3 a 4, príloha 5 až 8). Konkrétne ide o listnaté lesy klasifikované z dát Sentinel-2, ktoré pri metóde ML i SVM dosiahli hodnoty podielu rozlohy v rozmedzí 20 – 21 % a ihličnatých lesov z dát Landsat 8 – 70 %, resp. Sentinel-2 – 63 až 64 % (tab. 4). Podiel listnatých lesov (dáta

Landsat 8) je nižší hlavne kvôli nižšiemu priestorovému rozlíšeniu dát, ktoré ovplyvnilo klasifikáciu malých plôch listnatých lesov, resp. boli agregované pre nesplnenie podmienky najmenej mapevacej jednotky. Táto skutočnosť je očividná na celom území VO Brdy (obr. 3). Je viditeľné aj takmer rovnaké priestorové rozloženie plôch bez vegetácie z klasifikácií dát Sentinel-2. Badateľné je vyššie zastúpenie zastavaných plôch a plôch bez vegetácie pri použití algoritmu ML v porovnaní s algoritmom SVM.

5. Diskusia a záver

V našej štúdií bolo cieľom porovnať výsledné presnosti klasifikácie krajinej pokrývky vytvorené klasifikačnými algoritmi SVM a ML s využitím voľne dostupných satelitných snímok Landsat 8 a Sentinel-2. Zhodnotili a charakterizovali sme jednotlivé kroky procesu klasifikácie a posúdili jednotlivé faktory ovplyvňujúce správny výber a použitie zvolených metód. Jedným z najdôležitejších krokov klasifikácie krajinej pokrývky je vhodná identifikácia a vyznačenie tréningových plôch pre klasifikáciu. Po ich vyznačení sa musia štatisticky vyhodnotiť oddeliteľnosti jednotlivých tried, podľa nás najvhodnejšie metódou JM. Jej spojenie s analýzami priemerných hodnôt spektrálnych odrazivostí tried a ich smerodajných odchýlok v jednotlivých spektrálnych pásmach poskytuje takmer komplexný pohľad na nami vyznačené tréningové plochy a na ich možné správanie sa v procese klasifikácie.

Výsledky klasifikácií krajinej pokrývky boli relatívne uspokojivé – celkové presnosti boli vyššie než 85 %. Podľa predpokladu algoritmus SVM celkovou presnosťou prekonal algoritmus ML vo všetkých klasifikáciách. Predpoklad o vyššej presnosti klasifikácií z dát Sentinel-2 s vyšším priestorovým a spektrálnym rozlíšením oproti dátam Landsat 8 sa naplnil len čiastočne. Na detailnejšiu analýzu výsledkov je dôležité brať do úvahy aj presnosti jednotlivých tried krajinej pokrývky a ich priestorové rozloženie.

Porovnávaním podielu plôch jednotlivých tried krajinej pokrývky na celom území VO sme zistili tieto fakty. Na území VO Ralsko použitím rovnakého algoritmu nad rôznymi dátami sa objavili podobnosti výsledkov nielen v celkovej a používateľskej presnosti jednotlivých tried, ale aj v percentuálnych zastúpeniach tried krajinej pokrývky. Niektoré podiely plôch boli veľmi podobné. Táto podobnosť je zrejme nielen z tabuľkových hodnôt, ale aj priestorového rozloženia plôch znázornené na výstupoch klasifikácie krajinej pokrývky. Na území VO Brdy sa tento trend neobjavil, avšak sa vyskytli podobnosti na základe použitých satelitných snímok, napr. v podieloch ihličnatých a listnatých lesov použitím rozličných algoritmov nad tou istou snímokou. Z porovnávaní je zrejme aj to, že kvôli nižšiemu priestorovému, a zrejme aj spektrálnemu rozlíšeniu dát Landsat 8, sa na území VO Brdy klasifikoval menší podiel listnatého lesa v porovnaní s dátami Sentinel-2. Na odhalenie bližších súvislostí sú potrebné ďalšie výskumy v oblastiach zaniknutých i súčasných VO spoločnou aplikáciou dát Sentinel-2 a Landsat 8. Celkovo presnejšie výsledky dosiahnuté vo VO Brdy možno pripísať homogénnejšiemu územiu s nižším zásahom ľudskej činnosti, bez orných pôd, výrazne menším podielom zastavaných plôch (bez územia so solárnymi panelmi) a viac jednotvárnymi lesnými plochami oproti VO Ralsko.

Na základe dosiahnutých výsledkov sa klasifikátor SVM javí lepším a presnejším, ale na získanie ešte presnejších výsledkov sú treba merania in-situ pre detailné zameranie konkrétnych typov plôch, keďže neboli dostačujúce ani farebné ortofotosnímky. Opakované tréningovanie a oprava tréningových plôch, ktoré vedú k ich ešte lepšej oddeliteľnosti, môžu byť ďalším kľúčom k dosiahnutiu vyššej presnosti. V odbornej literatúre sa pre SVM zdôrazňuje vhodné nastavenie parametrov vstupujúcich do klasifikácie, preto je dôležité aj testovanie rôznych nastavení. Práve k tomuto testovaniu dát Sentinel-2 s rôznym prevzorkovaním alebo výberom iných spektrálnych pásiem by mohol smerovať ďalší výskum.

Autori ďakujú Grantové agentúre Univerzity Karlovy, konkrétne projektu „Hodnocení vlivu disturbance na lesní ekosystémy v Česku a na Slovensku pomocí metod DPZ“ (ID 512217), v rámci ktorého bol tento výskum realizovaný, spoločnosti TopGis, s.r.o. za poskytnutie služby WMS a Krajskému úradu Libereckého kraje za poskytnutie hraníc bývalého vojenského obvodu Ralsko.

Prílohy 1–8 Chybové matice výsledku klasifikácií

Príloha 1: Landsat 8 s algoritmom ML vo VO Brdy

Trieda krajinej pokrývky	vodné plochy	listnaté lesy	ihličnaté lesy	zastavané plochy	trávnatý porast	riedka vegetácia	bez vegetácie	celkom	Presnosť používateľa (v %)
vodné plochy	50	0	0	0	0	0	0	50	100
listnaté lesy	0	44	4	0	0	2	0	50	88
ihličnaté lesy	0	0	50	0	0	0	0	50	100
zastavané plochy	3	1	3	38	0	0	5	50	76
trávnatý porast	0	1	0	0	45	4	0	50	90
riedka vegetácia	1	6	2	0	1	40	0	50	80
bez vegetácie	0	0	0	4	1	1	44	50	88
celkom	54	52	59	42	47	47	49	350	
Presnosť spracovateľa (v %)	93	85	85	90	96	85	90		*88,86
Kappa koeficient									0.87

*celková presnosť

Príloha 2: Landsat 8 s algoritmom SVM vo VO Brdy

Trieda krajinej pokrývky	vodné plochy	listnaté lesy	ihličnaté lesy	zastavané plochy	trávnatý porast	riedka vegetácia	bez vegetácie	celkom	Presnosť používateľa (v %)
vodné plochy	50	0	0	0	0	0	0	50	100
listnaté lesy	0	44	3	0	0	3	0	50	88
ihličnaté lesy	0	4	46	0	0	0	0	50	92
zastavané plochy	0	0	0	46	0	0	4	50	92
trávnatý porast	0	0	0	0	48	2	0	50	96
riedka vegetácia	0	2	2	0	2	44	0	50	88
bez vegetácie	0	0	3	1	0	0	46	50	92
celkom	50	50	54	47	50	49	50	350	
Presnosť spracovateľa (v %)	100	88	85	98	96	90	92		92,57
Kappa koeficient									0.913

Príloha 3: Sentinel-2 s algoritmom ML vo VO Brdy

Trieda krajinej pokrývky	vodné plochy	listnaté lesy	ihličnaté lesy	zastavané plochy	trávnatý porast	riedka vegetácia	bez vegetácie	celkom	Presnosť používateľa (v %)
vodné plochy	50	0	0	0	0	0	0	50	100
listnaté lesy	0	44	4	0	0	2	0	50	88
ihličnaté lesy	0	1	49	0	0	0	0	50	98
zastavané plochy	8	0	2	26	0	0	14	50	52
trávnatý porast	0	0	0	0	44	6	0	50	88
riedka vegetácia	0	1	0	0	1	48	0	50	96
bez vegetácie	0	0	0	1	0	1	48	50	96
celkom	58	46	55	27	45	57	62	350	
Presnosť spracovateľa (v %)	86	96	89	96	98	84	77		88,29
Kappa koeficient									0.863

Príloha 4: Sentinel-2 s algoritmom SVM vo VO Brdy

Trieda krajinej pokrývky	vodné plochy	listnaté lesy	ihličnaté lesy	zastavané plochy	trávnatý porast	riedka vegetácia	bez vegetácie	celkom	Presnosť používateľa (v %)
vodné plochy	50	0	0	0	0	0	0	50	100
listnaté lesy	0	44	2	0	0	4	0	50	88
ihličnaté lesy	0	0	50	0	0	0	0	50	100
zastavané plochy	0	0	0	45	0	0	5	50	90
trávnatý porast	0	0	0	0	47	3	0	50	94
riedka vegetácia	0	1	2	0	1	45	1	50	90
bez vegetácie	0	0	1	1	0	2	46	50	92
celkom	50	45	55	46	48	54	52	350	
Presnosť spracovateľa (v %)	100	98	91	98	98	83	88		93,43
Kappa koeficient									0.923

Príloha 5: Landsat 8 s algoritmom ML vo VO Ralsko

Trieda krajinej pokrývky	vodné plochy	listnaté lesy	ihličnaté lesy	zastavané plochy	trávnatý porast	orná pôda	riedka vegetácia	bez vegetácie	celkom	Presnosť používateľa (v %)
vodné plochy	50	0	0	0	0	0	0	0	50	100
listnaté lesy	0	43	6	0	0	0	1	0	50	86
ihličnaté lesy	0	2	48	0	0	0	0	0	50	96
zastavané plochy	1	0	1	33	5	4	2	4	50	66
trávnatý porast	0	0	0	0	44	5	1	0	50	88
orná pôda	0	0	0	0	0	50	0	0	50	100
riedka vegetácia	0	4	2	0	5	0	39	0	50	78
bez vegetácie	0	0	0	8	0	3	2	37	50	74
celkom	51	49	57	41	54	62	45	41	400	
Presnosť spracovateľa (v %)	98	88	84	80	81	81	87	90		86,00
Kappa koeficient										0.84

Príloha 6: Landsat 8 s algoritmom SVM vo VO Ralsko

Trieda krajinej pokrývky	vodné plochy	listnaté lesy	ihličnaté lesy	zastavané plochy	trávnatý porast	orná pôda	riedka vegetácia	bez vegetácie	celkom	Presnosť používateľa (v %)
vodné plochy	49	0	0	1	0	0	0	0	50	98
listnaté lesy	0	48	2	0	0	0	0	0	50	96
ihličnaté lesy	0	1	49	0	0	0	0	0	50	98
zastavané plochy	0	0	0	45	2	0	0	3	50	90
trávnatý porast	0	1	0	0	45	3	1	0	50	90
orná pôda	0	0	0	0	1	48	0	1	50	96
riedka vegetácia	0	6	0	0	7	0	37	0	50	74
bez vegetácie	0	0	0	1	1	4	0	44	50	88
celkom	49	56	51	47	56	55	38	48	400	
Presnosť spracovateľa (v %)	100	86	96	96	80	87	97	92		91,25
Kappa koeficient										0.9

Príloha 7: Sentinel-2 s algoritmom ML vo VO Ralsko

Trieda krajiny pokrývky	vodné plochy	listnaté lesy	ihličnaté lesy	zastavané plochy	trávnatý porast	orná pôda	riedka vegetácia	bez vegetácie	celkom	Presnosť používateľa (v %)
vodné plochy	50	0	0	0	0	0	0	0	50	100
listnaté lesy	0	46	0	0	1	0	3	0	50	92
ihličnaté lesy	0	0	50	0	0	0	0	0	50	100
zastavané plochy	1	0	0	33	3	3	1	9	50	66
trávnatý porast	0	0	0	0	46	2	2	0	50	92
orná pôda	0	0	0	0	2	48	0	0	50	96
riedka vegetácia	0	6	2	0	4	0	38	0	50	76
bez vegetácie	0	0	1	4	2	4	2	37	50	74
celkom	51	52	53	37	58	57	46	46	400	
Presnosť spracovateľa (v %)	98	88	94	89	79	84	83	80		87,00
Kappa koeficient										0.851

Príloha 8: Sentinel-2 s algoritmom SVM vo VO Ralsko

Trieda krajiny pokrývky	vodné plochy	listnaté lesy	ihličnaté lesy	zastavané plochy	trávnatý porast	orná pôda	riedka vegetácia	bez vegetácie	celkom	Presnosť používateľa (v %)
vodné plochy	46	0	0	3	0	0	0	1	50	92
listnaté lesy	0	46	1	0	0	0	3	0	50	92
ihličnaté lesy	0	2	48	0	0	0	0	0	50	96
zastavané plochy	0	0	0	39	2	1	1	7	50	78
trávnatý porast	0	0	0	0	47	1	2	0	50	94
orná pôda	0	0	0	0	1	47	0	2	50	94
riedka vegetácia	0	4	3	1	4	0	38	0	50	76
bez vegetácie	0	0	0	1	0	10	0	39	50	78
celkom	46	52	52	44	54	59	44	49	400	
Presnosť spracovateľa (v %)	100	88	92	89	87	80	86	80		87,50
Kappa koeficient										0.857

Literatúra

- [1] AHMAD, A., QUEGAN, S. (2012). Analysis of Maximum Likelihood Classification on Multi-spectral Data. *Applied Mathematical Sciences*, 129, 6, pp. 6425-6436.
- [2] ARNOLD, S., KOSZTRA, B., BANKO, G., MILENOV, P., SMITH, G., HAZEU, G. (2016). *Explanatory Documentation of the EAGLE Concept*. Copenhagen (European Environment

- Agency).
- [3] BOSSARD, M., FERANEC, J., OŤAHEL, J. (2000). *CORINE Land Cover. Technical Guide – Addendum 2000*. Copenhagen (European Environment Agency).
 - [4] CANAZ, S., ALIEFENDIOĞLU, Y., TANRIVERMIŞ, H. (2017). Change detection using Landsat images and an analysis of the linkages between the change and property tax values in the Istanbul Province of Turkey. *Journal of Environmental Management*, 200, pp. 446-455.
 - [5] CORTES, C., VAPNIK, V. (1995). Support-Vector Networks. *Machine Learning*, 20, pp. 273-297.
 - [6] ESA (2015). *Sentinel-2 User Handbook*. Paris (European Space Agency).
 - [7] ESA (2018). Overview, Sentinel-2 MSI [online] [cit. 2018-04-24]. Dostupné na: <<https://earth.esa.int/web/sentinel/user-guides/sentinel-2-msi/overview>>
 - [8] HUANG, C., DAVIS, L.S., TOWNSHEND, J.R.G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 4, 23, pp. 725-749.
 - [9] KAPLAN, G., AVDAN, U. (2017). Mapping and Monitoring Wetlands Using SENTINEL-2 Satellite Imagery. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4, pp. 271-277.
 - [10] KARAN, S.K., SAMADDER, S.R. (2016). Accuracy of land use change detection using support vector machine and maximum likelihood techniques for open-cast coal mining areas. *Environmental Monitoring and Assessment*, 8, 188, pp. 1-13.
 - [11] KHATAMI, R., MOUNTRAKIS, G., STEHMAN, S.V. (2016). A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, 177, pp. 89-100.
 - [12] LIANG, S., LI, X., WANG, J. (2012). *Advanced remote sensing*. San Diego (Elsevier).
 - [13] LOVELAND, T.R., IRONS, J.R. (2016). Landsat 8: The plans, the reality and the legacy. *Remote Sensing of Environment*, 185, pp. 1-6.
 - [14] LU, D., WENG, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 5, 28, pp. 823-870.
 - [15] MIHAI, B., SĂVULESCU, I., RUJOIU-MARE, M., NISTOR, C. (2017). Recent forest cover changes (2002–2015) in the Southern Carpathians: A case study of the Iezer Mountains, Romania. *Science of the Total Environment*, 600, pp. 2166-2174.
 - [16] MO ČR (2016). Zrušení VÚ Brdy [online] [cit. 2018-04-08]. Dostupné na: <<http://www.mocr.army.cz/scripts/detail.php?id=92160>>
 - [17] MOUNTRAKIS, G., IM, J., OGOLE, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 3, 66, pp. 247-259.
 - [18] NOI, P.T., KAPPAS, M. (2018). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery. *Sensors*, 1, pp. 1-20.
 - [19] OTUKEI, J.R., BLASCHKE, T. (2010). Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, 12S, 12, pp. 27-31.
 - [20] PAL, M., MATHER, P.M. (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 5, 26, pp. 1007-1011.
 - [21] RUJOIU-MARE, M.R., OLARIU, B., MIHAI, B.A., NISTOR, C., SĂVULESCU, I. (2017). Land cover classification in Romanian Carpathians and Subcarpathians using multi-date Sentinel-2 remote sensing imagery. *European Journal of Remote Sensing*, 1, 50, pp. 496-508.
 - [22] SANCHEZ-HERNANDEZ, C., BOYD, D.S., FOODY, G.M. (2007). Mapping specific habitats from remotely sensed imagery: Support vector machine and support vector data description based classification of coastal saltmarsh habitats. *Ecological Informatics*, 2, 2, pp. 83-88.
 - [23] ŠLOSAR, V., DUBÁNEK, M., MINAŘÍK, P., URMINSKÝ, I. (2012). *Vojenské výcvikové prostory československé armády*. In: Baláž, J., Dubánek, M. eds. *Vojenský historický archiv - ročenka 2011*. Praha (Ministerstvo obrany České republiky – Odbor komunikace a propagace), s. 35-54.
 - [24] TOPALOĞLU, R., SERTEL, E., MUSAOĞLU, N. (2016). Assessment of classification accuracies of Sentinel-2 and Landsat-8 data for land cover / use mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B8, XXIII

ISPRS Congress, Prague, pp. 1055-1059.

- [25] TopGis (2018). *Prohlížeč služba WMS-ORTOFOTOMAPA ČR*. Brno.
- [26] USGS (2015a). Landsat 8 OLI/TIRS Level-2 Data Products – Surface Reflectance, Long Term Archive [online] [cit. 2018-04-18]. Dostupné na: <<https://lta.cr.usgs.gov/L8Level2SR>>
- [27] USGS (2015b). Sentinel-2, Long Term Archive [online] [cit. 2018-05-01]. Dostupné na: <https://lta.cr.usgs.gov/sentinel_2>
- [28] USTUNER, M., SANLI, F.B., ABDIKAN, S. (2016). Balanced vs imbalanced training data: Classifying rapideye data with support vector machines. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B7, XXIII ISPRS Congress, Prague*, pp. 379-384.
- [29] YU, L., LIANG, L., WANG, J., ZHAO, Y., CHENG, Q., HU, L., et al. (2014). Meta-discoveries from a synthesis of satellite-based land-cover mapping research. *International Journal of Remote Sensing*, 35(13), pp. 4573-4588.

S u m m a r y

Evaluation of remote sensing methods and data for land cover classification: case studies of former military training areas Brdy and Ralsko

The main goal of this study was to cross-compare accuracies of land cover classifications using Maximum Likelihood and Support Vector Machine classifiers with different data: Landsat 8 and Sentinel-2. As study areas were chosen military training areas Brdy and Ralsko in Czechia (Fig. 1 and Fig. 2). Starting with data acquisition, through data pre-processing, we paid attention to carefully choose classes of land cover, collect training areas and then to statistical test of these data. Methods Jeffries-Matusita distance and transformed divergences were evaluated as the best approaches to the statistical testing of training areas. Then we passed to the classification process in software ENVI using mentioned supervised classifiers and continued with post-processing by eliminating salt-and-pepper noise and smoothing the results according to minimal mapping unit – we set minimal mapping unit to 0.25 ha for Sentinel-2 and 0.5 ha for Landsat 8 data. The last step of the processing was accuracy assessment. In this step we generated 50 random points from every class of the result and we compared them with orthophotos, then results were summarised in error matrix, counting overall accuracies, user and producers accuracy and Kappa index (Appendixes 1–8).

The results were relatively satisfying – overall accuracies were higher than 85%, but we need to consider partial accuracies of separate classes, too. Overall more accurate results were released in military training area Brdy what we can attribute to his more homogenous area with lower human impact without arable lands, lower rate of built-up areas (without solar power plants) and more monotonous forest areas than in military training area Ralsko (Fig. 3). According to our hypothesis, classification results with SVM classifier overtook the results with ML in all cases. The second hypothesis, better results by Sentinel-2 data than with Landsat 8, was proved partially – only in the case of ML classifier.

Fig. 1 Location of study areas within Czechia

Fig. 2 Methodology

Fig. 3 Land cover classification outputs using Maximum Likelihood and Support Vector Machine classifiers with Landsat 8 and Sentinel-2 data for military training areas Brdy and Ralsko in 2016

Tab. 1 Comparison of Sentinel-2 and Landsat 8 spectral bands

Tab. 2 Description of classification classes

Tab. 3 Classification accuracy (in %) above Landsat 8 and Sentinel-2 data by ML and SVM classifiers in military training areas Brdy and Ralsko

Tab. 4 Share of individual land cover classes (in %)

Appendixes 1–8 Error matrix of the classifications assessment

Prijaté do redakcie: 13. júla 2018

Zaradené do tlače: december 2018