

## **Určenie druhového zloženia vegetácie z hyperspektrálnych dát metódami strojového učenia**

Bc. Max Timothy MARTIN

Školiteľ: doc. Mgr. Michal GALLAY, PhD.

Adresa: Ústav geografie, PF UPJŠ, Jesenná 5, 080 01 Košice, e-mail:

**Abstract: Determination of Species Composition of Vegetation from Hyperspectral Data using Machine Learning Methods:** *This work focuses on determining the species composition of vegetation from hyperspectral data using machine learning methods. This is an issue whose solution has the potential to significantly streamline vegetation mapping. Since each type of vegetation has its specific light reflection properties, hyperspectral images allow determining species composition, as well as other properties of plants based on this data. In this work, we focused on the area north of the village of Drienov in the Prešov District, where the location offered a diverse composition of plant species. We performed necessary corrections and conducted initial analyses on the data obtained using hardware owned by the Institute of Geography. Subsequently, we classified the data using multiple machine learning methods with ENVI software, resulting in varying levels of accuracy. Lidar data was also utilized to refine the process, and through the identification of individual tree segments, we developed our own method for cartographic representation of the results.*

**Keywords:** *hyperspectral imagery, spectral angle mapper, vegetation classification, machine learning*

### **Úvod**

Ústav geografie na Univerzite Pavla Jozefa Šafárika v Košiciach ako jedno z mála pracovísk v širšom regióne disponuje hardvérom a softvérom nevyhnutným pre zber a spracovanie hyperspektrálnych dát. Geoinformatika a obzvlášť diaľkový prieskum zeme (DPZ) zažívajú vo svete v ostatných rokoch rýchly pokrok spojený s technologickými možnosťami. Práve vďaka vybaveniu nášho ústavu sme schopní testovať a rozvíjať doterajšie poznanie z tohto perspektívneho odboru.

Klasifikácia vegetácie na základe dát z DPZ môže výrazne pomôcť k efektívnemu mapovaniu stavu v krajine, čo je užitočné pre lesníctvo, poľnohospodárstvo, geoekológiu, či biologický výskum. Umožňuje totiž nahradenie veľkej časti práce v teréne analýzou dát v softvéroch pracujúcich s hyperspektrálnymi dátami zozbieranými napríklad z bezpilotných leteckých zariadení. Okrem analýzy stavu krajiny môže táto technológia pomôcť v mitigácii rozširovania inváznych a škodlivých druhov v krajine. Rýchla a efektívna identifikácia jednotlivých druhov je v tomto prípade kľúčová pre včasné riešenie problému.

Cieľom tejto práce je predovšetkým klasifikácia hyperspektrálnych obrazových dát pomocou rôznych metód strojového učenia. Tieto metódy majú v mnohých vedných odboroch široké uplatnenie, pre každú aplikáciu je však vhodná iná metóda. V tejto práci je cieľom aj porovnanie rôznych metód, aby bolo možné pracovať s najvhodnejším spôsobom klasifikácie. Pre výsledky bude potrebné aj vytvorenie vhodného kartografického zobrazenia, ktoré by umožňovalo čo najjednoduchšiu interpretáciu výsledkov.

## **Teoretické východiská**

Hyperspektrálne skenovanie patrí medzi metódy diaľkového prieskumu zeme. Diaľkový prieskum zeme (DPZ) môže byť definovaný ako zhromažďovanie informácií o objektoch bez fyzického kontaktu s nimi. Zber dát sa vykonáva pomocou nosičov vo forme lietadiel, družíc, či iných podobných prístrojov. Termín diaľkový prieskum zeme je obmedzený na metódy, ktoré využívajú elektromagnetické žiarenie ako prostriedok k zisťovaniu objektov a meraniu ich charakteristík (Sabins, Freeman 1978).

Podstata hyperspektrálneho skenovania spočíva v zbere a spracovaní informácií naprieč elektromagnetickým spektrom (Chilton 2013). Na rozdiel od klasických kamier zaznamenávajúcich červené, zelené a modré spektrum - RGB - hyperspektrálne skenery zbierajú informácie o odrazivosti desiatok až stoviek rôznych vlnových dĺžok ako vo viditeľnom, tak aj mimo viditeľného spektra. Na rozdiel od klasických RGB snímok, kde má každý pixel priradenú hodnotu (vyjadrujúci pomer sledovaných vlnových dĺžok), pri hyperspektrálnych snímkach uvažujeme skôr v troch dimenziách. Okrem rozmerov „X“ a „Y“ tvoriacich priestorové rozlíšenie, sledujeme rozmer „Z“ tvorený spektrom elektromagnetického žiarenia. Pre jeden pixel sú priradené mnohé tenké pásma elektromagnetického žiarenia, čo vytvára takzvanú „dátovú kocku“, alebo „data cube“ (ESA 2014).

Výsledkom zberu priestorových dát v diaľkovom prieskume zeme sú viacrozmerné informácie. Okrem priestorového údaju vo forme súradnice (X,Y) obsahujú aj atribúty rôznej zložitosti. Napríklad pri práci s výškopisom sa jedná o informáciu obsahujúcu nadmorskú výšku, teda jednoduchý a diskretný číselný údaj. Pri multispektrálnych či hyperspektrálnych snímkach ale jeden pixel obsahuje veľké množstvo informácií o odrazivosti v rôznych spektrálnych pásmach. Tieto informácie potrebujeme pre účely druhového určenia vegetácie v priestore premeniť na jednoduchú informáciu o konkrétnej triede. Pre tento účel slúži široká paleta druhov klasifikácie. Klasifikácia je proces, pri ktorom sa jednotlivým obrazovým prvkom priradzuje určitý informačný význam. Cieľom je teda napríklad nahradiť radiometrické vlastnosti pôvodného obrazu vyjadrujúce spektrálne vlastnosti objektu informačnými triedami (Dobrovolný 1998). I keď do procesu klasifikácie vegetácie môžu vstupovať rôzne faktory a neexistuje jediná správna kombinácia vstupných faktorov (Campbell 1996), v našej práci sa zameriavame primárne na druhové určenie na základe informácií z hyperspektrálneho skenovania, teda z odrazivosti naprieč spektrami elektromagnetického žiarenia.

V ideálnom prípade by sme mali mať vo výsledku toľko klasifikovaných tried, koľko druhov vegetácie sa v záujmovom území nachádza. Limitácie ale nachádzame napríklad v priestorovom rozlíšení – nebudeme úplne schopní identifikovať rastliny, ktoré nepresahujú svojim

rozmerom priestorové rozlíšenie snímača. Limitujúcim faktorom pri druhovom určení je jednoznačne aj samotná klasifikácia, alebo aj dáta, na ktorých bude proces prebiehať. Tie sú totiž ovplyvnené šumom v dátach, alebo prirodzenými javmi ako tieň, vietor, či prašnosť.

## Dáta a ich spracovanie

Pre účely tejto práce sme zbierali dáta v katastri obce Drienov. Zaujímavé územie sa nachádza v severnej časti katastra v priestoroch bývalej kafilérie, západne od cesty III. triedy číslo 3445. Areál je špecifický vysokým počtom rôznych druhov vegetácie. Zatiaľ čo v juhozápadnej časti územia prevláda kultivovaná poľnohospodárska pôda, severozápad je pokrytý hustou stromovou vegetáciou.



**Obr. 1.** Vymedzené zaujímavé územie

Pre zber hyperspektrálnych dát bol použitý hyperspektrálny skener AisaKESTREL 10 od firmy SPECIM. Tento prístroj bol uvedený na trh v roku 2015 a je schopný zbierať dáta o odrazivosti elektromagnetického žiarenia z 92 vlnových dĺžok. Celkovo sníma spektrum široké 600 nm, konkrétne od vlnovej dĺžky 400 nm až po 1000 nm. Dáta sú teda zaznamenávané vo vlnových dĺžkach mimo viditeľného svetla. Skener sníma krajinu v zornom uhle 40° vo frekvencii 50 snímok za sekundu. Šírka snímky je 2048 pixelov, čo pri po-užívanej metóde zberu dát „push-broom“ vytvára dostatočne široké letové pásy pre prácu v našom zaujímavom území.

Surové dáta boli spracovávané skrz softvér CaliGeoPRO. Medzi procesy použité v tomto procese patrí rádiometrická korekcia a geometrická rektifikácia obrazu. Atmosferickou korekciou sme získali dáta o odrazivosti, ktoré na rozdiel od surových dát zobrazovali odrazivosť v reálnych fyzikálnych veličinách. Bez atmosferickej korekcie by nebolo možné pracovať so spektrálnymi knižnicami, keďže tie majú jasne definované odrazivosti v hodnotách od 0 (bez odrazu) po 1. Pre náš dataset sme použili bežne využívanú metódu FLAASH. Ortorektifikácia na základe DSM (digitálneho modelu povrchu) nebola vykonaná, nakoľko sme pre ju účely tejto práce nepovažovali za potrebnú.


Hlavnou náplňou práce je určenie druhového zloženia vegetácie. Preto po spracovaní dát korekciami sme odstránili plochy, ktoré nie sú tvorené rastlinstvom. Antropogénne prvky a odkrytú pôdu sme odstránili neriadenou klasifikáciou. V tomto kroku sme metódou klasifikácie ISODATA získali 6 tried, z ktorých sme vyčlenili tie, ktoré reprezentujú vegetáciu.

Pre redukciu počtu pásiem sme použili analýzu hlavných komponentov (PCA – Principal Component Analysis). Jedná sa o metódu slúžiacu na zníženie dimenzionality dát za čo najmenšej straty informácií (Sebera 2022). Spracovanie dát metódou analýzy hlavných komponentov sme vykonali v softvéri ENVI s vynechaním prvých štyroch pásiem, ktoré boli problematické pre ich výrazné zašumenie. Zo vstupných 88 pásiem sme získali 3, ktoré obsahujú drvivé množstvo informácií zachovaných vďaka zlučovaniu na základe lineárnej korelácie. Výsledkom po vykonaní všetkých vyššie uvedených krokov sú dáta pripravené pre vykonanie riadenej, ako aj neriadenej klasifikácie rastlinných druhov.

### **Práca s lidarovými dátami**

Mračno bodov sme pre záujmové územie vytvorili vďaka vlastnému zberu dát v rovnakom čase, ako sa konalo hyperspektrálne skenovanie. Použili sme letecký laserový skener Riegl VUX-1. So získaným mračnom bodov sme pracovali v softvéroch LAS tools, kde bola vyčlenená vegetácia vyššia ako 2 m nástrojom LAS classify. Z týchto bodov reprezentujúcich stromovú vegetáciu sme pomocou nástrojov z balíka lidR identifikovali vrcholy jednotlivých stromov. Okolo jednotlivých vrcholov boli následne vytvorené kruhové polygóny s priemerom 3 m. Takýto postup vyčlenenia jednotlivých stromov sme uznali za vhodnejší oproti segmentácii pomocou balíka lidR, pretože obmedzíme prekryt konárov a listov z rôznych stromov, nakoľko je vegetácia veľmi hustá a heterogénna. Pre účely tejto práce nám totiž plne postačujú menšie polygóny, ktoré ale tvoria vernejšiu a čistejšiu reprezentatívnu vzorku pre druhové určenie jednotlivých stromov.

Tento postup sa ukázal byť vhodný a presný aj po kontrole výsledkov priamo v teréne. Presnosť polohy určených bodov znázorňujúcich vrcholy stromov boli otestované pomocou GNSS zariadenia v teréne a to bez zistenia chýb. Úspešne sa nám podarilo identifikovať vrcholy stromov, od ktorých sme vytvorili polygóny reprezentujúce jednotlivé stromy.



**Obr. 2.** Jednotlivé identifikované stromy na základe práce s lidarovými dátami

### Klasifikácia

Pri spracovaní dát sme v našej práci použili rôzne druhy riadenej aj neriadenej klasifikácie. Z metód neriadenej klasifikácie sme využili ISODATA a K-Means. Pre záujmový región (ROI) tvorený živou vegetáciou prebehla klasifikácia s 10 iteráciami a so žiadaným výsledkom 9 tried.


Pre riadenú klasifikáciu je potrebné pracovať s tréningovou vzorkou, respektíve so spektrálnymi knižnicami. Tréningové vzorky sme získali terénnym meraním v záujmovom území. GNSS prístrojmi sme lokalizovali vrcholy stromov identifikované vyššie spomenutým postupom s lidarovými dátami. Pri stromoch, kde sa dal jednoznačne určiť ich druh, sme ho zapísali do atribútov. Pri riadenej klasifikácii sme očakávali výsledky s najvyššou výpovednou hodnotou u metódy Spectral Angle Mapper (SAM). Táto metóda využívajúca podobnosť uhlov medzi spektrami namiesto absolútnych hodnôt sa javí ako najvhodnejšia pre naše vysoko heterogénne územie. Ako najvhodnejšie sa empirickým zhodnotením javila byť klasifikácia SAM s nastavením maximálneho uhla 0,200 rad..

### Výsledky

Výsledkom zberu dát a ich spracovania korekciami je multidimenzionálny raster predstavujúci odrazivosť povrchov naprieč spektrami v záujmovom území. Priestorové rozlíšenie je 7 cm a počet spektrálnych pásiem je 92. Prvé 4 pásy sú však nepoužiteľné kvôli vysokému zašumeniu a zanedbateľnej výpovednej hodnote v kontexte identifikácie druhov vegetácie. Pre prvotnú kontrolu bola vytvorená ukážka dát v pravých farbách kde je viditeľné, že obraz




je správne rektifikovaný a geometrická korekcia prebehla pre účely práce správne a dostatočne presne. Dáta spracované korekciou FLAASH obsahujú informácie o odrazivosti v rámci jedného pixela naprieč všetkými spektrami. Každý pixel teda obsahuje unikátny spektrálny graf, ktorý sa líši odrazivosťou v rôznych spektrách a to na škále od 0 (bez odrazu) po 1. Práve na základe týchto atribútov sa dáta v softvéri ENVI klasifikovali pre vytvorenie výsledkov tejto práce.



**Obr. 3.** Zaujímavé územie v pravých farbách

Neriadená klasifikácia rastra do 9 tried bola vykonaná metódami K-Means a ISODATA. Vo výsledku týchto klasifikácií sa podarilo efektívne vyčleniť iba trávnatú vegetáciu. Stromová vegetácia bola klasifikovaná do nepoužiteľných tried. Jednotlivé triedy sú skôr výsledkami polohy listov, tieňov a množstva svetla. Jednotlivé druhy stromov nie je možné identifikovať. Výsledky ostatných použitých metód neriadenej klasifikácie boli veľmi podobné, bez výpovednej hodnoty vo veci klasifikácie stromovej vegetácie.




**Obr. 4.** Neriadená klasifikácia metódou ISODATA s 9 triedami

Riadená klasifikácia metódou Spectral Angle Mapper s tréningovými vzorkami získanými z lidarových dát a následným terénnym mapovaním identifikovala v hľadanom území hľadané druhy stromovej vegetácie. Keďže dostupné spektrálne knižnice neponúkajú dostatočne pestré zloženie stromovej vegetácie, ktorá by reprezentovala prítomné stromy typické pre región Torosy, museli sme od ich použitia upustiť. Najrozšírenejšie sú spektrálne knižnice


od The United States Geological Survey (USGS), ktoré sú však vytvorené primárne pre severoamerický trh a tam typickú vegetáciu. Klasifikácia teda prebehla na základe dát o odrazivosti z vrcholov stromov, ktorých druh sme určili v teréne.

Na mnohých miestach sa vytvorili zhľuky rovnako klasifikovaných pixelov, čo naznačuje koreláciu klasifikácie s reálnym stavom. Pri porovnaní s testovacou vzorkou identifikovaných stromov sme zistili, že väčšina stromov bola klasifikovaná nesprávne. V mnohých prípadoch boli nesprávne klasifikované stromy ako celky, často boli ale stromy chybné segmentované na niekoľko častí, kde jednotlivé segmenty vyšli vo výsledku ako rôzne druhy.



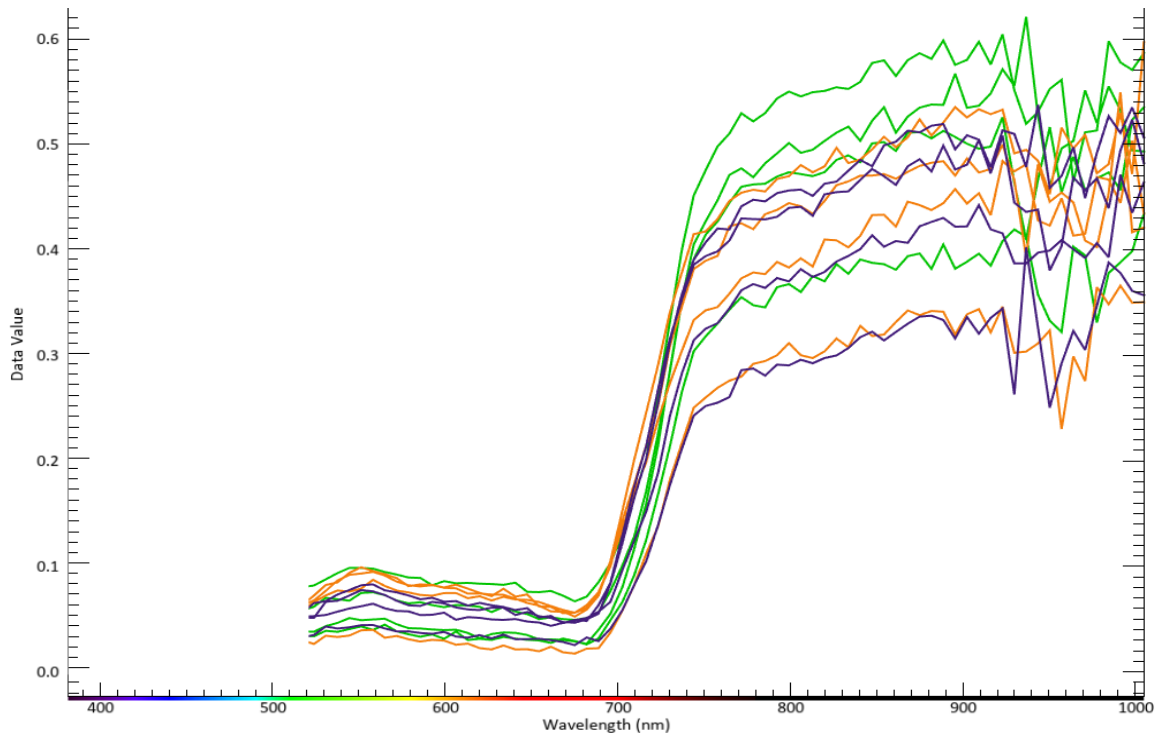
**Obr. 5.** Riadená klasifikácia stromovej vegetácie na záujmovom území metódou SAM

Keďže pôvodom tejto chyby mohol byť aj prekryt stromov v tomto husto zarastenom záujmovom území, vytvorili sme alternatívny spôsob kartografického zobrazenia výsledkov. Klasifikácie sú aplikované iba miesta, kde sa nachádzajú vrcholky stromov. Buffer s priemerom 3 m okolo vrcholov nám do veľkej miery odstráni spomínané riziko prekrytu stromov. Vytvorené zhľuky klasifikovaných pixelov sme zhladili. Napriek tomuto postupu sme získali vo väčšine stromov chybný výsledok. Kým klasifikácia prebiehala na náhodne vybraných stromoch, kontrola presnosti sa vykonala na zvyšných 11-tich stromoch, ktorých druhové určenie sme boli schopní jednoznačne určiť v teréne. Z 11-tich polygónov testovacej vzorky vyšla klasifikácia pomocou metódy SAM úspešne u dvoch, čo činí 18,2% presnosť.



**Obr. 6.** Výsledky klasifikácie metódou Spectral Angle Mapper aplikované na vrcholy stromov (farby znázorňujú jednotlivé druhy stromov vo výsledku klasifikácie: zelená – čerešňa, svetlo-modrá – topoľ, modrá – javor, červená – jelša, rúžová – vrbá, žltá – brest)

Pri analýze spektrálnych kriviek je možné si všimnúť, že krivky reprezentujúce pixely jedného druhu vegetácie vôbec nemajú jednoznačnú koreláciu. Je teda zrejmé, že nepresnosti nenastali pri klasifikácii dát, ale vychádzajú zo samotného datasetu.



**Obr. 7.** Spektrálne krivky znázorňujúce odrazivosť pixelov naprieč elektromagnetickým spektrom (zelená – vrbá, oranžová – jelša, fialová – brest)

## Záver

Na zvolenom datasete sa nám nepodarilo pomocou žiadnej z klasifikácií určiť druhy stromovej vegetácie s dostatočnou presnosťou. Pri neriadenej klasifikácii bol výstup nepoužiteľný, zatiaľ čo riadená klasifikácia pomocou metódy Spectral Angle Mapper sa ukázala mať väčší potenciál.

Príčin pre takýto výsledok je pravdepodobne viacero. Medzi hlavné patrí prítomnosť tieňov, čo skresľovalo reálnu odrazivosť vegetácie v zatienených častiach stromov. Podobným problémom je aj orientácia plochy listu vzhľadom na snímač, keďže vrchné a spodné strany listov majú iné optické vlastnosti pokiaľ ide o odrazivosť. Prekryt konárov rôznych druhov mohol miešať listy takým spôsobom, že znemožnili jednoznačné určenie druhu. Budúce práce zamerané na túto problematiku by sa pre aplikácie v slovenskom prostredí mohli zamerať aj na vytvorenie celistvej spektrálnej knižnice. Tu je priestor pre hlbšiu interdisciplinárnu spoluprácu aj v rámci Prírodovedeckej fakulty UPJŠ. Z hľadiska geoinformatiky by mohli prispieť k zlepšeniu presnosti výsledkov iné nastavenia parametrov v klasifikáciách, alebo aplikácia použitých metód v inom priestorovom rozlíšení.

## PodĎakovanie

Rád by som poďakoval pánovi doc. Gallayovi za pomoc pri orientovaní sa v problematike, doc. Kaňukovi za zber dát v teréne a Mgr. Svetozarovovi za asistenciu pri práci s lidarovými dátami.



## **Literatúra**

- CAMPBELL, J. B., 1996: Introduction to Remote Sensing. Taylor & Francis. Londýn. pp. 662.
- CHILTON, A., 2014: The Working Principle and Key Applications of Infrared Sensors. AZO-Sensors. [cit. 2023-07-31]. <https://www.azosensors.com/article.aspx?ArticleID=339>
- EUROPEAN SPACE AGENCY, 2014: Hyperspectral image 'data cube'. [cit. 2023-07-31]. [https://www.esa.int/ESA\\_Multimedia/Images/2014/04/Hyperspectral\\_image\\_data\\_cube](https://www.esa.int/ESA_Multimedia/Images/2014/04/Hyperspectral_image_data_cube)
- DOBROVOLNÝ, P., 1998: Dálkový průzkum Země, Digitální zpracování obrazu. Brno (Masarykova Univerzita).
- SABINS, F. F., FREEMAN, W. H., 1978: Remote sensing: principles and interpretation. Cartography, 11(4), pp. 251–252.
- SEBERA, M., 2012: Vícerozměrné statistické metody. Brno (FSpS, Masaryková Univerzita).