

KOMBINÁCIA HYPERSPEKTRÁLNYCH MATERIÁLOV DPZ A ÚDAJOV LETECKÉHO LASEROVÉHO SKENOVANIA PRI URČOVANÍ DREVINOVÉHO ZLOŽENIA

THE COMBINATION OF HYPERSPECTRAL DATA MADE BY REMOTE SENSING AND DATA OF AIRBORN LASER SCANNING IN DETERMINATION OF TREE SPECIES COMPOSITION

ŠIMON SALOŇ

Hospodárska úprava lesov, LF, TUZVO,
T. G. Masaryka 24, 960 53, Zvolen, SR
simonsalon@centrum.sk

Abstrakt

Práca sa venuje kvalitatívnemu klasifikovaniu zvoleného územia (s hlavným dôrazom na drevinové zloženie) za pomoci algoritmu Gaussian maximum likelihood v softwarovom prostredí ENVI 5.0 na podklade hyperspektrálnych dát zabezpečených prostredníctvom systému AISA EAGLE.

Druhá časť práce je venovaná kombinácii takto klasifikovaného územia rastrovej reprezentácie s výstupom leteckého laserového scanu, ktorý nám poskytuje odvodenú polohu objektov reprezentujúcich korunové projekcie jednotlivých drevín. Sekundárnym zámerom práce je vytvorenie, analýza a implementácia hyperspektrálnych kriviek jednotlivých tried do hyperspektrálnej knižnice, na základe ktorých je možné automatizovane klasifikovať zvolené územie. Výsledkom sú mapové výstupy rastrovej a vektorovej reprezentácie popisujúce polohu jednotlivých klasifikovaných objektov.

Záver práce je venovaný demonštrácii využiteľnosti finálnych výstupov pre potreby precízneho lesníctva ako plnohodnotného multifunkčného zdroja informácií pre podporu rozhodovania sa.

Kľúčové slová: hyperspektrálne dáta, letecký laserový scan, lesníctvo, GIS

Abstrakt:

The thesis is focused on the use of hyperspectral data in combination with airborne laser scanning in forestry concerned on classification of various tree species. The first part of the thesis is dedicated to a brief theory related to the issue, in which are characterized the hyperspectral data, the spectral behaviour of the vegetation, the spectral classification of picture, the classification algorithm and airborne laser scanning. The second part is dealing with technical description of experimental material and the methodology of processing and evaluation of available data of airborne laser scanning and hyperspectral data provided by AISA Eagle system. The result of the thesis are percentual evaluations of classification accuracy for various tree species with use of classification algorithm of Gaussian maximum likelihood and spectral angle mapper with application with various spectral range. The end of the thesis summarizes the results, describing the observations and acquired problems while solving the issue, as well as a proposition for amelioration of classification accuracy and enhancement of automatization level.

Key words: hyperspectral data, airborne laser scanning, forestry, GIS

1. ÚVOD A CIELE

Neustále sa rozvíjajúce technológie a metodiky spracovania dát na rôznej úrovni automatizácie v integrácii s GIS (geografickými informačnými systémami) poskytujú bohatú paletu informácií s takmer neobmedzenou využiteľnosťou v rôznych odvetviach hospodárstva i mimo nich. V lesnom hospodárstve možno využiť celú škálu technológií na zabezpečovanie potrebných a primerane presných informácií pri tvorbe PSL. Pri určovaní hraníc jednotlivých JPRL sa momentálne využíva prevažne fotogrametria, GNSS technológie, geodetické metódy a letecky laserový scan. Pri odvodzovaní porastových veličín a určovaní hraníc JPRL (jednotiek priestorového rozdelenia lesa) má najväčšiu perspektívu práve letecky laserový scan. Všetky tieto technológie sa navzájom integrujú a dopĺňajú. V poslednom období sa dostáva dopopredia aj využívanie hyperspektrálnych materiálov, ktoré zachytávajú odraznosti jednotlivých prvkov v rôznych vlnových dĺžkach, na báze ktorých sa určuje kvalita a teda sa prisudzuje príslušnosť prvku do jednotlivej triedy.

Práca je zameraná na využiteľnosť hyperspektrálnych dát získaných systémom AISA Eagles v kombinácii s vhodne spracovanými dátami leteckého laserového scanu (ALS) pre odvetvie lesného hospodárstva.

Cieľom práce je :

- vhodným metodickým postupom na podklade hyperspektrálnych dát klasifikovať záujmové územie s primárnym zameraním na drevinové zloženie,
- z dát leteckého laserového scanu odvodiť korunové projekcie jednotlivých drevín zvolenej časti porastu,
- posúdiť vhodnosť využitia výstupov integrujúcich letecké laserové scanovanie a hyperspektrálne dáta, ako možnej vhodnej inventarizačnej metódy pri zbere a vyhodnocovaní časti dát pre potreby precízneho lesníctva.

2 PROBLEMATIKA

Tvorbou a využitím multispektrálnych a hyperspektrálnych dát sa zaoberá DPZ (diaľkového prieskumu Zeme). Cieľ DPZ je zameraný na určovanie kvality. Využíva poznatky o vlastnostiach elektromagnetického žiarenia. Jednotlivé povrchy objektov majú pri interakcii s jednotlivými vlnovými dĺžkami elektromagnetického žiarenia rôznu úroveň odraznosti. Táto skutočnosť tvorí podstatu princípu pri spektrálnej klasifikácii obrazu. S ohľadom na aplikáciu hyperspektrálnych dát pre určovanie druhov drevín je na obr. č.1 uvedené priemerne spektrálne správanie sa vegetácie, ktoré je podrobnejšie analyzované v kapitole 2.2 Spektrálne správanie sa vegetácie.

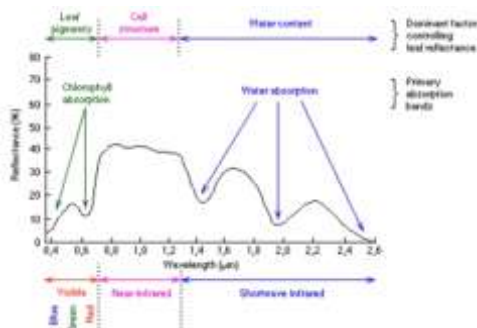
2.1 Hyperspektrálne dáta

Doposiaľ nebola záväzne prijatá presná definícia charakterizujúca hyperspektrálne dáta. Na základe dostupných údajov však možno zhrnúť a opísať najdôležitejšie špecifiká, ich výhody a nevýhody. Základným znakom hyperspektrálnych dát je, že obsahujú veľké množstvo spektrálnych kanálov elektromagnetického žiarenia. Tie zachytávajú odraznosti jednotlivých objektov a javov v úzkych (od 10 μm) na seba nadväzujúcich intervaloch elektromagnetického spektra pri zachytávaní rôzneho celkového elektromagnetického spektra.

Práve tento technický parameter predurčuje tieto dáta k multifunkčnému využitiu. Vedia jemnejšie a presnejšie zachytávať a opisovať spektrálne správanie sa objektov, čo má napríklad veľký význam pri sledovaní zmien odraznosti vegetácie v rámci rôznych časových

radov (sledovanie a vyhodnocovanie fenológie,...). Medzi nevýhody hyperspektrálnych dát patrí ich náročné spracovanie zamerané na rádiometrické a geometrické korekcie.

2.2 Spektrálne správanie sa vegetácie



Obrázok 1: Spektrálne správanie sa vegetácie

http://nptel.ac.in/courses/105104100/lectureD_20/D_20_3.htm

Ako možno vidieť, spektrálne správanie sa vegetácie (ich listov) v jednotlivých vlnových dĺžkach ovplyvňujú v najväčšej miere tri faktory, ktorých rozpätia sú schematicky znázornené v uvádzanom obrázku nad textom. Odraznosť vegetácie v prvom rozpätí vlnových dĺžok (0.400 µm – cca 0.650 µm) sa mení primárne v závislosti od listových pigmentov (chlorofyl a, b, karotenoidy, fykobiliny,...), ktoré výrazne pohlcujú elektromagnetické žiarenie v týchto vlnových dĺžkach. V rozpätí vlnových dĺžok (0.650 µm – 1.3 µm) má výrazný vplyv na zmenu odraznosti bunková štruktúra orgánov jednotlivých druhov vegetácie. Uvádzané rozpätie ponúka vysokohodnotné informácie, na základe ktorých je možné už vizuálne (porovnávaním) identifikovať celú paletu objektov a javov s ohľadom na zameranie. Tretia časť elektromagnetického žiarenia (1.3 – 2.6 µm) je výrazne pohlcovaná v závislosti od podielu vody v pletivách. Každý druh vegetácie má svoju identickú krivku spektrálneho správania sa. Práve tento fakt je predmetom skúmania pri ich klasifikácii. Tu ale nastáva problém tzv. zmiešaného pixelu, ktorého problematiku podrobnejšie rieši VAN DER MEER, et. al.2001.

2.3 Spektrálna klasifikácia obrazu

Pod pojmom klasifikácia obrazu rozumieme zatriedovanie obrazových prvkov do tried na základe vopred stanovených kritérií. Dnešné digitálne rastrové reprezentácie môžu nadobúdať hodnoty v rozsahu až 24-bit, čo predstavuje 16 777 216 možných hodnôt v rámci pixelu pri snímaní. Pri hyperspektrálnych dátach sú tieto snímky buď v 12-bitovom alebo 16-bitovom formáte. Potencionálne vedú tieto 16-bitové snímky zachytiť až 65 536 stupňov odraznosti, ktoré sa v počítačovom prostredí vizuálne prejavujú rôznym stupňom odtieňov sivej, s ktorými vie počítač pracovať a ďalej vyhodnocovať. Len ťažko si možno predstaviť človeka schopného rozpoznať 65 536 odtieňov sivej, ktorý by dokázal takéto dáta zatriedovať a klasifikovať len na základe ich odtieňa. Pod spektrálnou klasifikáciou obrazu rozumieme automatizované zatriedovanie jednotlivých pixelov do tried prostredníctvom rozhodovacích pravidiel (algoritmov), ktoré zohľadňujú hodnoty DN charakterizujúce spektrálnu odraznosť objektov a javov zachytených v rámci pixelu.

Spektrálna klasifikácia obrazu sa delí na:

- a) nekontrolovanú,
- b) kontrolovanú.

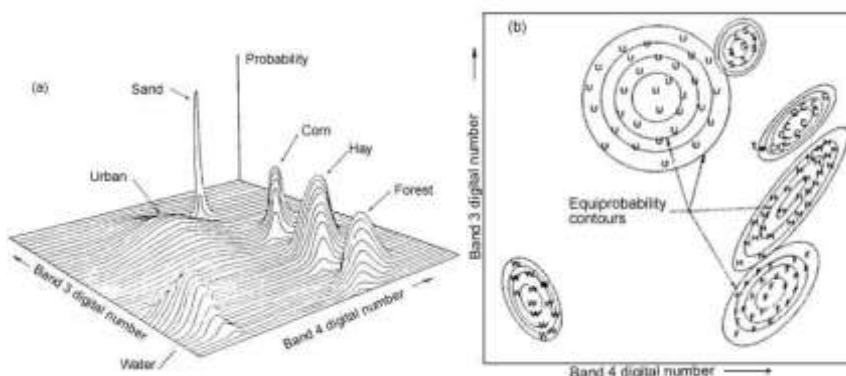
2.4 Kontrolovaná klasifikácia – Gaussian maximum likelihood

Pri kontrolovanej klasifikácii poznáme vopred klasifikačné triedy, ktoré identifikujeme priamo pri terénnych prácach (referenčné údaje). Všetky identifikované objekty patriace do príslušnej triedy tvoria tréningovú množinu, na podklade ktorej sa vytvára interpretačný kľúč z hodnôt DN v jednotlivých vlnových dĺžkach. Prostredníctvom vytvoreného interpretačného kľúča sa po porovnávaní zatriedujú jednotlivé obrazové prvky do príslušných tried.

a) Gaussov klasifikačný algoritmus maximálnej pravdepodobnosti

Algoritmus je založený na princípe klasifikácie využívajúcej rozptyl a kovarianciu exaktne vytvorených tréningových množín (ROI). Pri klasifikácii vychádza z normálneho rozdelenia hodnôt DN v rámci jednotlivých tréningových množín. Vlastnosti výberového súboru (hodnoty DN) popisuje mierou polohy, ktorou je priemer. Ten určuje polohu priemernej DN hodnoty v rámci 2D priestoru. Veľkosť je definovaná mierou variability a to rozptylom, pričom jej tvar a orientácia je popísaná kovarianciou, ktorá je kalkulovaná v rámci regresnej a korelačnej analýzy. Z týchto parametrov sa pre každý obrazový prvok vstupujúci do klasifikácie vypočíta štatistická pravdepodobnosť pre každú jednu stanovenú triedu. Prvok bude teda zaradený do triedy podľa vypočítanej najväčšej pravdepodobnosti, pri zohľadnení všetkých pravdepodobností voči triedam. Potrebná prahová pravdepodobnosť sa volí pri parametroch klasifikácie. Výhodou tejto metódy je, že zohľadňuje kolísanie DN hodnôt a že nedochádza k preklasifikovaniu (zaradeniu jedného obrazového prvku k dvom triedam). Nevýhodou je však prácnosť a časová náročnosť pri zohľadnení potrebných terénnych štetreniach (ŽIHĽAVNÍK, Š., SCHEER, I. 2001).

Rozšírením o Bayesovu klasifikáciu možno dosiahnuť optimálnejšie výsledky. Princíp spočíva v zohľadňovaní dvoch faktorov pri každej klasifikovanej triede. Ide o pridelenie rôznej pravdepodobnosti v závislosti od výskytu určitého prvku v klasifikovanej oblasti a priradeniu váhy nákladov spojených s chybnou klasifikáciou (THOMAS M.LILLESAND, et al. 2008). Schematické zobrazenie popisujúce princíp práce algoritmu je na obr. 11. Zobrazenie princípu práce algoritmu GAUSSIAN MAXIMUM LIKELIHOOD v: a) 3D priestore, b) 2D priestore.



Obr. 1: Zobrazenie princípu práce algoritmu GAUSSIAN MAXIMUM LIKELIHOOD v: a) 3D priestore, b) 2D priestore

Zdroj: http://nptel.ac.in/courses/105104100/lectureD_28/D_28_4.htm

Pri tomto parametrickom algoritme sa dosahujú pri vyhodnocovaní presnosti najlepšie výsledky. Avšak na druhej strane vyžaduje precíznu prípravu a zber dát, ktoré sú časovo a finančne náročné.

3EXPERIMENTÁLNY MATERIÁL A METODIKA

3.1 Experimentálny materiál

Experimentálny materiál pozostával z/zo:

- a) pracovnej mapy vhodnej spektrálnej kompozície doplnenej o bodové pole polygónového ťahu,
- b) stabilizovaného a signalizovaného bodového poľa polygónového ťahu, ktoré slúžilo ako hlavný orientačný prvok v lesnatej záujmovej lokalite pri zbere potrebných informácií,
- c) bodov zameraných GNNS prijímačom (Trimblegeo xh6000 series), zachytávajúcich polohu záujmových prvkov,
- d) opisu porastov LHC z aktuálneho PSL pre vybranú lokalitu,
- e) dát leteckého laserového scanu,
- f) hyperspektrálnych dát systému *AISA eagle*.

Pre širšie súvislosti uvádzame podrobnejšie informácie o hyperspektrálnych dátach:

- priestorová rozlišovacia schopnosť snímky: 0.5 m
- rádiometrické rozlíšenie: 16-bit (65 536 možných hodnôt DN výsledného rastra pri snímaní)
- spektrálne rozlíšenie : 10 μm
- spektrálny rozsah: 0.400 – 1.000 μm
- počet spektrálnych pásiem: 65
- projekčný súradnicový systém: UTM 32
- časový aspekt: 8.7 – 10.7

3.2Metodika

3.2.1 Prípravné práce

Prípravné práce pozostávali z/zo:

- a) analýzy dostupných hyperspektrálnych materiálov celého VŠLP a zvolenie záujmovej lokality,
- b) tvorby vektorovej vrstvy vizuálne farebne odlišných objektov, ktoré budú pri terénnych prácach predmetom prešetrovania,
- c) vytvorenia terénnej mapy, ktorej obsah bol nasledovný:
 - rastrová podkladová vrstva bola tvorená vhodnou kompozíciou spektrálnych pásiem, výsledkom ktorej bola letecká snímka v nepravých farbách (v kvázi červenom spektre ju tvorila vrstva (band) s vlnovou dĺžkou 0,810 μm ,v zelenom spektre 0,680 μm a modrom spektre 0,587 μm ,
 - vektorová vrstva charakterizovala polohu zameraných bodov polygónového ťahu a záujmových objektov, ktoré bolo potrebné pri terénnom šetrení identifikovať a kvalitatívne zatriediť do tried,
 - gridová vrstva v spone 50 x 50 m naprieč mapovým listom znázorňovala priebeh projekčnej siete a zlepšovala tak orientáciu v záujmovej lokalite

-mimorámové údaje dopĺňali praktickú využitelnosť terénnej mapy, šlo najmä o mierky (číselná, grafická), legendu, severku a textovú časť.

Prvotná analýza prebiehala cez modul 2D Scatter plot, kde bolo možné nahrubo vizuálne identifikovať hierarchicky najvyššie (dobre separované) triedy, ktoré reprezentovali štruktúru lokality (listnaté dreviny, ihličnaté dreviny, lúka, cesta).

3.2.2 Terénne práce

Terénne práce sa zameriavali hlavne na prešetrovanie, identifikovanie a kvalitatívne zatriedovanie objektov vytvorenej vektorovej vrstvy do tried. Pre orientáciu v teréne sa využívalo existujúce bodové pole polygónového ťahu, vytvorená terénna mapa a buzola. Zároveň sa do terénnej mapy zakresľovala poloha a plocha prvkov, ktoré boli mimo vytvorenej vektorovej vrstvy a budú:

- a) plošne rozširovali už existujúce kvalitatívne triedy,
- b) vylišovali nové kvalitatívne triedy.

V tomto bode však nastal časom popri šetrení problém. Problém týkajúci sa miery zohľadňovania detailu pri vyčleňovaní tried v závislosti od záujmu lesníctva. Pri vyčleňovaní tried boli použité nasledovné kritéria:

- a) plošné zastúpenie v lokalite (lúka, cesta,...),
- b) identifikovateľnosť na snímke,
- c) druhová príbuznosť objektov a ich zlúčenie (zjednodušenie) pri čo najmenšej strate informácií.

K príkladu možno uviesť prípad dvoch druhov drevín z rodu *Pinus* v rámci lokality. Dominantným druhom bola *Pinus sylvestris* L., zároveň sa v lokalite nachádzala aj *Pinus strobus* L., ktorá nieje v lokalite rozšírená a na snímke nieje rozpoznateľná. Jej plošné zastúpenie by nepostačovalo na vytvorenie ROI podľa odporúčaných kritérií, o ktorých bude zmienka nasledujúcej kapitole: 4.2.3 Kancelárske práce. Na podklade týchto informácií bolo rozhodnuté, že aj keď sa tento druh dreviny v záujmovom území nachádza, nebude pre ňu vytvorená osobitná kvalitatívna skupina. Zároveň sa lokalita s jej výskytom nezaraďovala do ROI pre drevinu *Pinus sylvestris* L.. Rovnako táto lokalita nevstupovala ani ako kontrolná referenčná plocha. Tým sa zamedzilo zbytočnému skresľovaniu výstupných štatistík (pre ROI) a následným skresleniam pri hodnotení presnosti klasifikácie. Pre výskumne účely postačovalo v určitých prípadoch vytvoriť triedy pre jednotlivé rody drevín (pr. *Crataegus* sp.). Súčasťou terénnych prác bol aj odber zimných púčikov sporných nezaraďovaných, ale na snímke identifikovaných druhov drevín. Je potrebné si uvedomiť, že hyperspektrálne dát poskytvajú multifunkčný zdroj informácií a je len na nás, aby sme vhodne stanovili predmet skúmania, od ktorého sa bude odvíjať proces mapovania.

3.2.3 Kancelárske práce

V tejto fáze sa systematicky spracovávali údaje a dáta z terénneho šetrenia. Postupne sa podľa odporúčaných metód a kritérií dospelo k prechodným a finálnym výstupom, z ktorých boli kalkulované a interpretované výsledky.

Pre zhrnutie sa v tejto kapitole budeme v krátkosti venovať:

- a) tvorbe masky (vylúčenie zatienených častí z klasifikácie),
- b) trénovacím množinám (ROI), kontroly ich odlučiteľnosti a vizualizácie, tvorba referenčných dát
- c) tvorbe hyperspektrálnych kriviek a ich exportovaním do spektrálnej knižnice,
- d) klasifikačnému algoritmu Gaussian Maximum Likelihood (zvoleným parametrom pri klasifikácii)
- e) metodike spracovania LIDAR dát a tvorbe korunových projekcií
- f) zonálnej štatistike

Spracovanie prebiehalo v softwarovom prostredí ENVI 5.0 od firmy EXELIS, Exell od firmy MICROSOFT a ArcMap 10.2 od firmy ESRI.

a) Výsek záujmového územia a tvorba masky reprezentujúcu tieň

V softwarovom prostredí ENVI cez modul *RESIZE DATA* bolo vyextrahované záujmové územie so všetkými vlnovými dĺžkami, ktoré bolo definované polygónom vo vektorovej reprezentácii. Masku v tomto ponímaní možno opísať ako časť územia, ktorá nemá vstupovať do klasifikácie. V našom prípade išlo o vytvorenie masky pre časti územia výrazne zatienené. Dôvodom je fakt, že zatienené časti objektov majú iné spektrálne chovanie, ako aj iné hodnoty DN, čo by výrazne ovplyvnilo štatistické charakteristiky výberových súborov jednotlivých tried. Pre tento účel bola po analýze vybraná vrstva z hyperspektrálnych dát, ktorá opticky najviac vystihuje polohu tieňa. Výber vrstvy prebehol čisto subjektívne a celkovo je táto časť spracovania údajov a tvorba výstupov výlučne subjektívna. Pre tento účel bola zvolená vrstva 42 zachytávajúca vlnovú dĺžku 0.7727 μm . Za pomoci histogramu bola určená hraničná hodnota DN, po ktorú budeme všetky rastre s danou hodnotou DN klasifikovať ako tieň. Pre tento prípad boli všetky rastre s hodnotou DN v intervale 0 – 1100 DN (okrem cesty, ktorá bola v druhom kroku vypustená) klasifikované cez modul *RECLASSIFY* ako tieň. Rastrová reprezentácia bola prevedená cez modul *RASTER TO POLYGON* do vektorovej reprezentácie.

b) Tvorba tréningových množín (ROI) a referenčných dát

Cez modul *ROI TOOLS* v prostredí ENVI 5.0, boli postupne vytvárané polygóny charakterizujúce polohu objektov patriacich jednotlivým triedam. Minimálny počet rastrov tvoriacich výberový súbor jednej triedy, pre ktorú budú kalkulované štatistické charakteristiky bol zvolený na 650 rastrov na jednu triedu. Pri stanovení potrebného rozsahu výberového súboru sme sa snažili držať odporúčani podľa LILLESAND *et al.* (2008), ktorý uvádza, že rozsah výberového súboru by sa mal pohybovať na úrovni 10n až 100n, kde n je množstvo spektrálnych kanálov analyzovaných hyperspektrálnych dát. V našom prípade to predstavovalo $10 \times 65 = 650$ potrebných pixelov na triedu. Vytvárané ROI boli podľa situácie rovnomerne priestorovo usporiadané tak, aby zabezpečovali čo najlepšiu reprezentatívnosť. Pre takto vytvorené ROI prebehla v module *COMPUTE ROI SEPARABILITY*, ktorý používa na výpočet vzdialenosti *Jeffries-Matusitov* algoritmus, kalkulácia oddeliteľnosti jednotlivých tried. Výsledkom je koeficient v rozsahu od 0 po 2. Hodnota 0 indikuje žiadnu (zlú) separabilitu medzi porovnávanou dvojicou trieda hodnota 2 indikuje vysokú separabilitu. Všeobecne možno už výsledky z hodnotou nad 1.9 možno považovať za uspokojivé (THOMAS *et al.* 2001).

V druhej časti týchto prác boli spracované a vytvorené aj tzv. referenčné dáta, ktoré charakterizovali polohu jednotlivých porovnávacích tried, na báze ktorých prebiehalo zisťovanie presnosti klasifikácie. Po analýze oddeliteľnosti jednotlivých tried sa pristúpilo ku kalkulácii štatistických charakteristík pre jednotlivé triedy cez modul *COMPUTE ALL STATISTIC*. Oddeliteľnosť jednotlivých tried je možné vizualizovať v module *N-DIMENSIONVISUALIZER*.

c) Tvorba hyperspektrálnych kriviek a ich export do hyperspektrálnej knižnice:

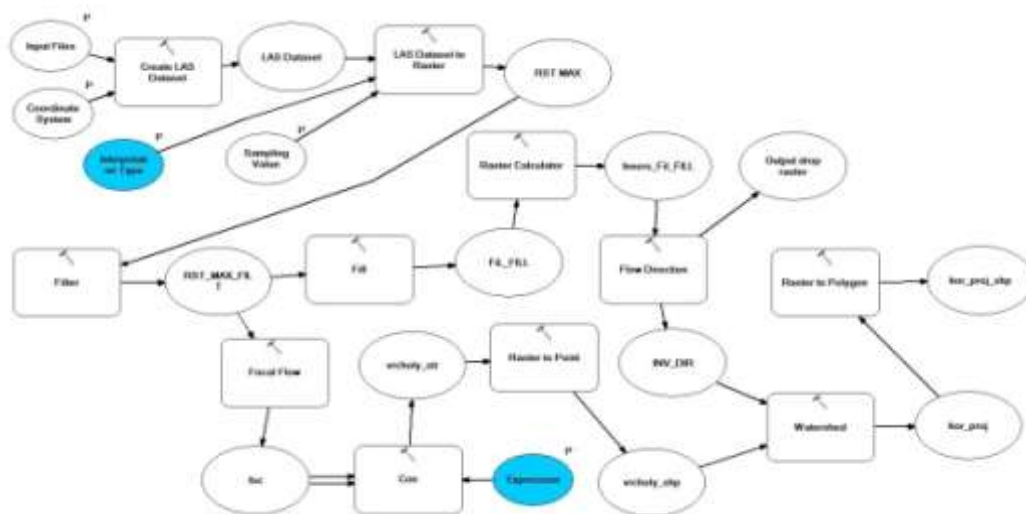
Po zohľadnení všetkých skutočností s ohľadom na minimálny rozsah výberového súboru a potvrdenú oddeliteľnosť sa pristúpilo ku kalkulácii štatistických charakteristík opisujúcich spektrálne správanie jednotlivých tried, ktoré prebehlo v module *COMPUTE ALL STATISTIC*. Výsledkom kalkulácie bola podrobná štatistika pozostávajúca z regresnej a korelačnej analýzy a z mier polohy a variability. Súčasťou výstupov sú aj hyperspektrálne krivky jednotlivých tried odzrkadľujúcich ich priemerné spektrálne správanie sa v rámci jednotlivých vlnových dĺžok. Tieto empiricky získané krivky možno exportovať do spektrálnej knižnice, ktorá slúži ako zdroj informácií pri klasifikačnom algoritme SAM.

d) *Klasifikácia lokality prostredníctvom parametrického algoritmu Gaussian Maximum Likelihood*

Je to algoritmus zohľadňujúci rozptyl a kovariáciu tréningových množín, pričom pri výpočte ráta s Gausovým normálnym rozmiestnením DN hodnôt vytvorených tréningových množín. Ako vstup pre klasifikáciu sme použili výsek záujmového územia a všetky založené a overené ROI. Hodnota pravdepodobnosti pri klasifikácii bola pre všetky triedy nastavená na 0.1. V prvom kroku bolo záujmové územie klasifikované pri zohľadnení full setu (pri použití všetkých vlnových dĺžok od 0.400 μm po 1.00 μm), a v druhom kroku iba z rozpätia spektrálnych vlnových dĺžok od 0.700 μm po 1.000 μm . Dôvodom bol fakt, že v tomto rozmedzí vlnových dĺžok je už vizuálne lepšia odlišiteľnosť jednotlivých tried.

e) *metodika spracovania LIDAR dát a tvorba korunových projekcií:*

Samotnej metodike spracovania sa venuje viacero autorov a výskumných tímov. Pre potreby odvodenia korunových projekcií drevin bola použitá metodika podľa Michaela Swamera, ktorý odvodzuje korunové projekcie na báze tvorby povodí. Na obrázku 17. Spracovanie dát ALS: podľa metodiky Michael Swamer, je znázornený celý proces spracovania laserových dát, ako aj odvodzovania korunových projekcií v prostredí ArcMap10.2 prostredníctvom modulu *model builder* (obrázok 2).



Obrázok 2: Spracovanie LAS – odvodzovanie korunových projekcií

f) *Zonálna štatistika*

Klasifikované územie v rastrovej reprezentácii bolo exportované z prostredia ENVI 5.0 vo formáte TIFF, ktorý je čitateľný pre software ArcMap, v ktorom prebiehalo ďalšie spracovanie. Do založeného projektu boli naimportované vytvorené korunové projekcie. Cez modul *ZONAL STATISTIC AS TABLE* prevezmeme a pridáme atribúty majoritného zastúpenia pixelov danej triedy polygónu, do ktorého spadajú. Výsledkom je po prepojení cez *JOIN TABLE* vektorová reprezentácia korunových projekcií, ktorá ma naplnenú databázu s informáciami o identite jednotlivých korunových projekcií vo vzťahu k drevinám.

5 VÝSLEDKY

Pri terénnych prácach bolo v záujmovom území nájdených 16 druhov drevín a to: *Pinus sylvestris* L., *Pinus Strobus* L., *Juniperus comunis* L., *Abies alba* Mill., *Picea abies* L., *Larix decidua* Mill., *Betula pendula* Roth., *Fagus sylvatica* L., *Quercus* sp., *Cerasus avium* L., *Tilia* sp., *Populus* sp., *Carpinus betulus* L., *Acer pseudoplatanus* L., *Fraxinus excelsior* L., *Crataegus* sp.,

Nie všetky druhy drevín však spĺňali požiadavku na minimálny rozsah výberového súboru, ktorý mal byť tvorený z minimálne 650 pixelov. Niektoré druhy drevín neboli na hyperspektrálnych dátach ani identifikovateľné. Z týchto dôvodu boli vylúčené z budúcej klasifikácie dreviny *Juniperus comunis* L., *Pinus strobus* L., *Abies alba* Mill., *Cerasus avium* L., *Populus* sp..

V tab. č.1: Popis mapovaných prvkov, je uvedený prehľad identifikovaných drevín, ich množstvo pixelov, z ktorých sa skladali trénovacie množiny (tvorili výberový súbor pre kalkuláciu štatistických charakteristík), počet lokalít, z ktorých sa skladali, ako aj množstvo nájdených a identifikovaných referenčných dát.

Tab. č.1: Popis mapovaných prvkov

Mapovaný prvok	výmera referenčných prvkov v pixloch	Počet referenčných plôch	výmera kontrolných referenčných prvkov v pixloch
<i>Larix decidua</i> Mill.	133	3	-
<i>Picea abies</i> L.	942	13	943
<i>Pinus sylvestris</i> L.	935	8	1,173
<i>Fraxinus excelsior</i> L.	335	1	-
<i>Betula pendula</i> Roth.	201	1	-
<i>Tilia</i> sp.	661	7	747
<i>Acer platanoides</i> L.	284	1	-
<i>Carpinus betulus</i> L.	682	6	1,671
<i>Crataegus</i> sp.	408	3	534
<i>Quercus</i> sp.	693	4	2,123
<i>Fagus sylvatica</i> L.	788	5	965
Cesta	449	4	540
Pokosená lúka	2,476	2	5,240
Nepokosená lúka	976	2	1,205

Ako vidieť v tabuľke č. 1: Popis mapovaných prvkov, pre finálnu klasifikáciu bolo vybraných a použitých 14 tried, z ktorých len 8 spĺňalo kritérium minimálnej výmery výberového súboru (sivo vyznačené bunky). Pri štyroch triedach dokonca absentovalo potrebné množstvo referenčných dát v pixeloch pre zhodnotenie presnosti klasifikácie. (*Larix decidua* Mill., *Fraxinus excelsior* L., *Betula pendula* Roth., *Acer platanoides* L.)

Tab. č.2: Vplyv použitého elektromagnetického rozpätia na presnosť klasifikácie Gaussian maximum likelihood v %

Trieda	Nahodnotenie		Podhodnotenie		Prod.Acc.		User Acc.	
	0.7-1.0	0.4-1.0	0.7-1.0	0.4-1.0	0.7-1.0	0.4-1.0	0.7-1.0	0.4-1.0
	1.0 μ m	μ m	μ m	μ m	μ m	μ m	μ m	μ m
Carpinus betulus L. cesta	33.77 0.68	24.7 0	20.23 0	62.9 0	79.77 100	37.1 100	66.23 99.32	75.3 100
Crataegus sp.	27.82	0	1.15	37.18	98.85	62.82	72.18	100
Fagus sylvatica L. nepokosená lúka	15.67 2.75	44.02 0	28.68 2.1	11.32 1.09	71.32 97.9	88.68 98.91	84.33 97.25	55.98 100
Picea abies L.	5.77	9.51	11.78	2.56	88.22	97.44	94.23	90.49
Pinus sylvestris L. pokosená lúka	4.46 0.06	2.12 0.21	3.29 0.66	4.68 0	96.71 99.34	95.32 100	95.54 99.94	97.88 99.79
Quercus sp.	15.34	14.75	13.78	16.91	86.22	83.09	84.66	85.25
Tilia sp.	5.7	36.62	34.35	0.4	65.65	99.6	94.3	63.38

Charakteristika hodnotení k tab. č.2:

- Chyby z nahodnotenia (Errors of Commission). Popisujú, aká časť referenčných dát bola zaradená do nesprávnych klasifikačných tried.

- Chyby z podhodnotenia (Errors of Omission). Popisujú, akéj časti klasifikovaných dát boli priradené nesprávne referenčné dáta, resp. pravá presnosť v zameraní, či klasifikovaný pixel padol alebo nepadol do referenčných dát, ktoré mu odpovedajú.

- Produčtenská správnosť (Producer's Accuracy). Opisuje presnosť všetkých klasifikovaných tried, kde sa pri výpočte porovnávajú referenčné triedy s jednotlivými klasifikovanými triedami.

- Uživateľská správnosť (User's Accuracy). Opisuje presnosť klasifikovaných tried, pričom porovnáva každú jednu klasifikovanú triedu individuálne s referenčnými triedami.

V tabuľke č.2 je uvedené zhodnotenie presnosti klasifikácie (v %). Je to len zlomok informácií o presnosti klasifikácie, preto hodnotíme len tie najpodstatnejšie: nahodnocovanie jednotlivých tried, podhodnocovanie jednotlivých tried, produčtenská presnosť a uživateľská presnosť. Sivou farbou je vyznačená produčtenská presnosť z dôvodu že nám popisuje presnosť z podhodnotenia, kde boli priamo porovnávané referenčné dáta s vyprodukovanými. V tabuľke jasne vidieť, že použitý algoritmus dosahuje väčšiu presnosť pri použití spektrálneho rozpätia od 0.7-1.0 μ m. Dokonca bolo z celkového množstva 15 141 referenčných pixelov klasifikovaných pri tomto rozpätí 13 366 pixelov oproti 11 480 pixelom pri použití elektromagnetického rozpätia 0.4-1.0 μ m. Klasifikovalo sa teda viac pixelov pri vyššej presnosti. Trieda Crataegus sp. je najviac zasiahnutá zmiešaním pixelu, keďže pixel reprezentujúci polohu danej triedy obsahoval aj značnú časť triedy lúka. Preto táto trieda reagovala na zníženie presnosti pri použití celého rozparia elektromagnetického spektra.

Tab. č.3: Vplyv použitého elektromagnetického rozpätia na presnosť klasifikácie SAM v %

Trieda	Nahodnotenie		Podhodnotenie		Prod.Acc.		UserAcc.	
	0.7-1.0	0.4-1.0	0.7-1.0	0.4-1.0	0.7-1.0	0.4-1.0	0.7-1.0	0.4-1.0
	μm	μm	μm	μm	μm	μm	μm	μm
Carpinus betulus L.	33.77	24.7	20.23	62.9	79.77	37.1	66.23	75.3
cesta	0.68	0	0	0	100	100	99.32	100
Crataegus sp.	27.82	0	1.15	37.18	98.85	62.82	72.18	100
Fagus sylvatica L.	15.67	44.02	28.68	11.32	71.32	88.68	84.33	55.98
nepokosená lúka	2.75	0	2.1	1.09	97.9	98.91	97.25	100
Picea abies L.	5.77	9.51	11.78	2.56	88.22	97.44	94.23	90.49
Pinus sylvestris L.	4.46	2.12	3.29	4.68	96.71	95.32	95.54	97.88
pokosená lúka	0.06	0.21	0.66	0	99.34	100	99.94	99.79
Quercus sp.	15.34	14.75	13.78	16.91	86.22	83.09	84.66	85.25
Tilia sp.	5.7	36.62	34.35	0.4	65.65	99.6	94.3	63.38

V tabuľke č.3 je uvedené zhodnotenie presnosti klasifikácie (v %). Sivou farbou je vyznačená producentská presnosť z dôvodu, že nám popisuje presnosť z podhodnotenia, kde boli priamo porovnávané referenčné dáta s vyprodukovanými. V tabuľke vidieť, že použitý algoritmus dosahuje väčšiu presnosť pri použití spektrálneho rozpätia od 0.4-1.0 μm . Z celkového množstva 15 141 referenčných pixelov klasifikovaných pri tomto rozpätí 7 911 pixelov oproti 11 622 klasifikovaným pixelom pri použití elektromagnetického rozpätia 0.7-1.0 μm . Pri rozpätí 0.4-1.0 μm bolo klasifikovaných menej pixelov pri vyššej presnosti. Najnižšia presnosť klasifikácie bola dosiahnutá pri triede *Carpinus betulus* L.. Na jej úkor bola nahodnotená najmä trieda *Quercus* sp.

Pri porovnaní použitých algoritmov možno zhodnotiť, že pri aplikácii algoritmu Gaussian maximum likelihood je vhodnejšie použiť rozpätie elektromagnetického žiarenia rozpätia 0.7-1.0 μm . Naopak pri použití algoritmu SAM je vhodnejšie použiť vždy celé dostupné zachytené elektromagnetické pole, čiže opačne ako pri aplikácii algoritmu Gaussian maximum likelihood kedy je vhodnejšie použiť už spomínané elektromagnetické rozpätie 0.7-1.0 μm

Tab. č. 4: Porovnanie presnosti a správnosti v závislosti od elektromagnetického rozpätia

Klasifikačný algoritmus	Rozpätie μm	OA %	Kappa index	Δ_n
Gaussian maximum likelihood	0.400 - 1.00	89,477	0,8687	$\pm 0,00629$
	0.700 - 1.00	90,695	0,8862	$\pm 0,00949$
SAM	0.400 - 1.00	83,3017	0,8031	$\pm 0,00822$
	0.700 - 1.00	78,8246	0,7198	$\pm 0,00743$

V tabuľke č.4 vidíme zhrnutie opisujúce : rozpätie, celkovú presnosť klasifikácie (OA %), kappa koeficient a očakávanú odchýlku od klasifikácie.


OA % - celková presnosť klasifikácie nám popisuje koľko všetkých obrazových prvkov bolo klasifikovaných správne

Kappa koeficient: popisuje koľko % chýb sme odstránili pri použití algoritmu s danými parametrami pri daných podmienkach, ktoré by vznikli, ak sme použili úplne náhodnú klasifikáciu.

Δ_p - odchýlka od kappa indexu nám charakterizuje náhodnú chybu, ktorú môžeme očakávať pri klasifikácii s titulu pôsobenia náhodných faktorov.

Jednou z možností zlepšenia klasifikácie je spojenie výsledných klasifikačných rastrov s výsledkami leteckého laserového scanu v prostredí ArcMap cez modul *Zonal statistic as table* pri nastavení zohľadňovania majoritnej početnosti pixelu padnutého do jednotlivých polygónov reprezentujúcich korunové projekcie. Výsledkom sú teda korunové projekcie jednotlivých druhov drevín doplnené o atribúty z podkladového rastra (obr. č.3). Presnejšie korunové projekcie pre účely porovnávania by bolo možné získať napr. použitím technológie Field-Map (TOMAŠTÍK, TUNÁK 2015), čo by ale bolo neúmerne časovo náročnejšie.

Pri aplikácii tejto fúzie vychádzame z podstaty, že nieje potrebné klasifikovať všetky obrazové prvky, ale iba tie, ktoré s najväčšou pravdepodobnosťou spadajú do danej triedy. Tieto kritéria sa nastavujú pri klasifikácii.



Obrázok č.3: Korunové projekcie s priradeným atribútom drevín

6 ZÁVER

Na základe dosiahnutých výsledkov možno potvrdiť perspektívnosť využiteľnosti hyperspektrálnych dát v kombinácii s laserovým leteckým scanom. S novými prístupmi a metódami spracovania ALS možno očakávať zvýšenie presnosti pri odvodzovaní korunových projekcií (podľa VEGÁ C.; DURRIEU, S, bola dosiahnutá presnosť pri identifikácii 73.97%), a zamedziť tak napr. ich nadmernej fragmentácii alebo naopak prílišnému zhlukovaniu. Za týchto predpokladov možno očakávať celkové zlepšenie presnosti pri pridelovaní atribútov z rastrovej vrstvy (výstupu klasifikácie) vektorovej (korunové projekcie jednotlivých drevín).

Po analýze výsledkov tejto fúzie sme dospeli k záveru, že nieje nutné klasifikovať všetky rastre skúmaného územia, ale iba tie, ktoré budú skutočne reprezentovať danú triedu pri požadovanej presnosti. To je potrebné zabezpečiť pri nastavení hraničných kritických hodnôt pri vybranej klasifikácii. Podmienkou pre zonálnu štatistiku je, aby aspoň jeden raster charakterizujúci konkrétnu triedu padol do polygónu reprezentujúceho korunovú projekciu dreviny, ktorej bude priradený atribút z rastra. Je však nutne podotknúť, že pre prepojenie týchto dvoch technológií je potrebné ich precízne predspracovanie (geometrické korekcie, georeferencovanie, rádiometrické korekcie, ...). Ďalším možným riešením pre krok vpred k automatizovanému spracovaniu je vytvorenie hyperspektrálnych kriviek významných druhov drevín v laboratórnych podmienkach, pričom by sa pri vytváraní kriviek zohľadňovala fenofáza, ontogenéza a zdravotný stav dreviny. Disponovaním takýmito dátami by sa zamedzilo prácnym terénnym prácam zameraných na zber k tvorbe tréningových množín a zúžil by sa len na zisťovanie presnosti klasifikácie a zberu referenčných dát, prípadne by sa len prešetrovali polohy klasifikovaných druhov drevín. V neposlednom rade je potrebné spomenúť problematiku tzv. čistoty pixelu reprezentujúceho istý povrch, respektíve jeho mixu v reálnych podmienkach, ktorý ovplyvňuje hodnotu DN a tým zasahuje do celkového výsledku klasifikácie. Záverom možno zhrnúť, že aj keď je tu veľa otázok, je možné očakávať progres týchto technológií smerom k presnosti a úrovni automatizácie.

6 POUŽITÁ LITERATÚRA

[1] LILLESAND, T., M., KIEFER, R., W., CHIPMAN, J. W., 2008. *Remote sensing and image interpretation*. 6th edition. USA, 2008. 804 pages. ISBN 978-0-470-05245-7.

[2] SWAMMER, M. [cit. 2015.03.02] Dostupné na internete:
<http://web.pdx.edu/~jduh/courses/geog493f12/Projects/SwamerHouser.pdf>

[3] TOMAŠTIK, J., TUNÁK, D., 2015. *Compass measurement still a suitable surveying method in specific conditions*. Geodesy and Cartography 41(1), Taylor & Francis, s. 31-40

[4] THOMAS, V. et al., 2002. Image classification of northern peatland complex using spectral and plant community data [online]. In *Remote sensing of environment 84*, 2002.p. 83 – 99. [cit. 2015.02.26] Dostupné na internete:
http://www.yorku.ca/jrmiller/Papers/03Thomas_RSE_FenClassification.pdf

[5] ŽÍHLAVNÍK, Š., SCHEER, L., 2001. *Dial'kový prieskum Zeme v lesníctve*. Zvolen: Vydavateľstvo TU Zvolen, 2001. 289 s. ISBN 80-228-0991-8