



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

**Fakulta elektrotechnická
Katedra radioelektroniky**

Analysis of Hyperspectral Images

Analýza hyperspektrálních obrazových dat

Diplomová práce

Studijní program: Audiovizuální technika a zpracování signálů

Studijní obor: Elektronika a komunikace

Vedoucí práce: prof. Mgr. Petr Páta, Ph.D.

Bc. Pavel Tymeš

Praha 2020

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Tymeš** Jméno: **Pavel** Osobní číslo: **434983**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra radioelektroniky**
Studijní program: **Elektronika a komunikace**
Studijní obor: **Audiovizuální technika a zpracování signálů**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Analýza hyperspektrálních obrazových dat

Název diplomové práce anglicky:

Analysis of Hyperspectral Images

Pokyny pro vypracování:

Seznamte se s principem a metodami hyperspektrálního zobrazování. Zaměřte se především na metody odhadu hlavních složek ('endmembers'). Vytvořte vhodnou databázi hyperspektrálních dat. Podejte přehled metod k hyperspektrálnímu rozkladu ('hyperspectral unmixing'). Vybrané metody implementujte a porovnejte jejich účinnost.

Seznam doporučené literatury:

- [1] ZHUANG, Lina, Chia-Hsiang LIN, Mario A. T. FIGUEIREDO a Jose M. BIOUCAS-DIAS. Regularization Parameter Selection in Minimum Volume Hyperspectral Unmixing. IEEE Transactions on Geoscience and Remote Sensing [online], 1-20, DOI: 10.1109/TGRS.2019.2929776. ISSN 0196-2892.
- [2] BIOUCAS-DIAS, Jose M., Antonio PLAZA, Gustavo CAMPS-VALLS, Paul SCHEUNDERS, Nasser NASRABADI a Jocelyn CHANUSSOT. Hyperspectral Remote Sensing Data Analysis and Future Challenges. IEEE Geoscience and Remote Sensing Magazine [online]. 2013, 1(2), 6-36, DOI: 10.1109/MGRS.2013.2244672. ISSN 2168-6831.
- [3] BHATT, Jignesh S. a Manjunath V. JOSHI. Regularization in Hyperspectral Unmixing. BHATT, Jignesh S. a Manjunath V. JOSHI. Regularization in Hyperspectral Unmixing [online]. SPIE PRESS, 2016, DOI: 10.1117/3.2264037. ISBN 9781510607590.
- [4] SMITH, Randall B., Introduction to Hyperspectral Imaging. Microimages.com [online]. 2012.

Jméno a pracoviště vedoucí(ho) diplomové práce:

prof. Mgr. Petr Páta, Ph.D., katedra radioelektroniky FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **22.09.2019**

Termín odevzdání diplomové práce: _____

Platnost zadání diplomové práce: **19.02.2021**

prof. Mgr. Petr Páta, Ph.D.
podpis vedoucí(ho) práce

doc. Ing. Josef Dobeš, CSc.
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomant bere na vědomí, že je povinen vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

Datum převzetí zadání

Podpis studenta

Čestné prohlášení

Prohlašuji, že diplomovou práci "Analýza hyperspektrálních obrazových dat" jsem vypracoval samostatně pod vedením vedoucího práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu literatury na konci práce. Jako autor uvedené práce dále prohlašuji, že jsem v souvislosti s jejím vytvořením neporušil autorská práva třetích osob.

V Praze dne 28. 7. 2020

Poděkování

Rád bych touto cestou poděkoval panu *prof. Mgr. Petrovi Pátovi, Ph.D.* za cenné připomínky, trpělivost a odborné vedení při vypracování této práce.

Analýza hyperspektrálních obrazových dat

Anotace:

Diplomová práce se zabývá metodou analýzy hyperspektrálních dat – hyperspektrálním rozkladem. Snímky pořízené v oblasti vzdáleného snímání jsou zatíženy jevem spektrálního míchání. Algoritmy hyperspektrálního rozkladu umožňují identifikovat hlavní složky zaznamenaného snímku (endmembers) a jejich rozložení na zaznamenané scéně (abundance). Jedním z důležitých kroků hyperspektrálního rozkladu je odhad průběhů těchto hlavních složek. V rámci této práce je popsáno dělení metod odhadu hlavních složek se zaměřením na geometrické přístupy. Vybrané algoritmy z této skupiny byly popsány a byla testována jejich účinnost. Testy byly provedeny v programu Matlab na vybraných snímcích z reálných systémů, a také na synteticky vytvořených datech.

Klíčová slova:

hyperspektrální zobrazování, vzdálené snímání, spektrální míchání, hyperspektrální rozklad, spektrální znak, odhad endmembers, čistý pixel, spektrální úhel

Analysis of Hyperspectral Images

Annotation:

This thesis deals with the method of analysis of hyperspectral data - hyperspectral unmixing. The images captured in the area of remote sensing are affected by the effect of spectral mixing. The algorithms of hyperspectral unmixing aim to identify the endmembers (materials within a scene) and their relative abundance. An important part of the unmixing is endmember estimation. This work describes the division of methods for endmember estimation, with a focus on geometric approaches. Selected algorithms were described and their efficiency was tested. The tests were performed in Matlab on selected images from real systems, as well as on synthetically generated data.

Keywords:

hyperspectral imaging, remote sensing, spectral mixing, hyperspectral unmixing, spectral signature, endmember estimation, pure pixel, spectral angle

Obsah

1	Úvod	8
2	Základy optiky	10
2.1	Elektromagnetické záření	10
2.2	Elektromagnetické spektrum	11
2.3	Disperze záření	11
2.3.1	Optický hranol	12
2.4	Difrakce	12
2.4.1	Difrakční mřížka.....	13
3	Zobrazování v prostoru (x, y) a ve spektru (λ)	15
3.1	Standardní 2D zobrazování.....	16
3.2	Spektroskopie	17
3.2.1	Spektrometr.....	18
3.3	Multispektrální zobrazování	20
4	Hyperspektrální zobrazování.....	22
4.1	Datacube	22
4.2	Využití a aplikace hyperspektrálního zobrazování.....	23
4.3	Technologie hyperspektrálních kamer	25
4.3.1	Skenovací metody zobrazovací spektroskopie	25
4.3.1.1	Bodové skenování (whiskbroom).....	26
4.3.1.2	Řádkové skenování (pushbroom).....	26
4.3.1.3	Pásmová sekvenční metoda (staring)	27
4.3.2	Snapshot technologie spektrálního zobrazování	27
4.3.2.1	Integral field spectroscopy (IFS)	28
4.3.2.2	Multiaperture Filtered Camera (MAFC).....	28
4.4	Parametry Hyperspektrálních kamer	29
5	Analýza hyperspektrálních dat	31
5.1	Preprocessing (konverze změřené radiance na odpovídající reflektanci).....	32
5.2	Zobrazení ve spektrálním prostoru	34
5.3	Spektrální míchání (spectral mixing)	35
5.4	Hyperspektrální rozklad (Hyperspektral Unmixing = HU)	37

5.4.1	Linear Mixing Model (LMM)	39
5.4.1.1	Řetězec hyperspektrálního rozkladu (hyperspectral unmixing chain).....	41
5.5	Metody odhadu hlavních složek (endmembers estimation).....	42
5.5.1	Statistické metody	43
5.5.2	Metoda řídké regrese (sparse regression = SR)	43
5.5.3	Geometrické metody - pure pixel based.....	44
5.5.3.1	Pure Pixel index (PPI).....	45
5.5.3.2	Vertex Component Analysis (VCA).....	46
5.5.3.3	N-FINDR.....	47
5.5.3.4	Alternating Volume MAXimization (AVMAX)	48
5.5.4	Geometrické metody - Minimum Volume (MV) based.....	49
5.5.4.1	SISAL	51
5.5.4.2	NMF-QMV.....	52
6	Databáze hyperspektrálních dat	54
6.1	Reálné HSI snímky	54
6.1.1	Parametry a formát dat	57
6.2	Synteticky vytvořené HSI snímky.....	59
6.2.1	Synthesis tools package (HYDRA).....	60
6.2.2	Spektrální knihovna.....	63
6.2.3	Funkce spectMixGen (J. M. Bioucas-Dias).....	66
7	Hlavní skript.....	68
7.1	Výběr a nahrání vstupních dat	68
7.2	Zobrazení vstupních dat.....	68
7.3	Redukce dimenze (HYSIME)	69
7.4	Algoritmy hyperspektrálního rozkladu	70
7.5	Zobrazení výstupních dat.....	70
7.6	Vyhodnocení pro syntetická data	71
7.7	Konec skriptu.....	75
8	Testování algoritmů HU	76
8.1	Syntetická data.....	76
8.1.1	Výpočetní čas.....	78
8.1.2	Opakování pro shodná data.....	78

8.1.3	SNR.....	80
8.1.4	Počet endmembers.....	83
8.2	Reálná data	85
8.2.1	Jasper Ridge.....	86
8.2.2	Cuprite.....	88
9	Závěr.....	90
10	Seznam použité literatury	91
11	Seznam obrázků.....	98
12	Seznam zkratek a symbolů.....	102
12.1	Anglické pojmy.....	102
12.2	Zkratky.....	102
12.3	Proměnné.....	103
13	Seznam příloh.....	104

1 Úvod

Hyperspektrální snímání je moderní oblast zobrazovací technologie, která poskytuje nové možnosti pro analýzu zaznamenaných dat. Tato technologie nachází mnohá využití, ať už v průmyslu či zemědělství. Velká část aplikací spadá do vzdáleného snímání (remote sensing), kde je ze vzduchu zaznamenáván povrch země.

Princip Hyperspektrálních kamer spočívá v kombinaci principů standardního 2D zobrazování a spektroskopie. Jejich výstupem je hyperspektrální snímek obsahující prostorovou i spektrální informaci. Zaznamenaná data si lze představit jako 3D (x,y,λ) kostku, tzn. datacube. Předchůdcem této technologie bylo multispektrální zobrazování, které se vyznačovalo malým množstvím širokých spektrálních pásem. Oproti tomu hyperspektrální kamery umožňují zaznamenání spektrální informace ve stovkách úzkých, na sebe navazujících spektrálních pásmech.

Značná část aplikací hyperspektrální technologie spočívá v identifikaci obsažených materiálů a jejich rozložení na zaznamenané scéně. Každý materiál interaguje odlišně s dopadajícím elektromagnetickým zářením. Vlna může materiálem projít, odrazit se od něj nebo může být část její energie pohlcena. Této skutečnosti se využívá v oblasti spektroskopie i v oblasti hyperspektrálního snímání. Zaznamenává se odražené (reflektance) spektrum daného materiálu, na základě jeho tvaru, tzv. spektrálního znaku (spectral signature), lze rozlišovat jednotlivé materiály.

Technologické pokroky mají za následek navyšující se objem zaznamenaných dat, a tím pádem vysoké nároky na metody analýzy. Kromě toho jsou hyperspektrální snímky zatíženy šumem a jevem nazvaným spektrální míchání, jehož důsledkem není možné přímo z pořízených snímků určit rozložení materiálů na snímané scéně.

Existuje několik přístupů k analýze hyperspektrálních dat. Jednou z důležitých oblastí je hyperspektrální rozklad (unmixing). Algoritmy hyperspektrálního rozkladu umožňují identifikovat hlavní složky zaznamenaného snímku (endmembers) a následně dopočítat jejich procentuální rozložení na zaznamenané scéně (abundances). Podle toho, jakým způsobem je přistupováno k řešení této problematiky rozlišujeme lineární (statistické, geometrické nebo řídká regrese) či nelineární metody hyperspektrálního rozkladu.

Tato práce se zaměřuje na popis a následné porovnání vybraných algoritmů geometrického hyperspektrálního rozkladu umožňujících odhad hlavních složek (endmember estimation).

Byla sestavená databáze hyperspektrálních dat. Tato databáze obsahuje jak reálné snímky, tak i prostředky na sestavení snímků syntetických. Většina reálných snímků z této databáze byla pořízena z různých systémů v oblasti vzdáleného snímání (AVIRIS, HYSIME, aj.), ale bylo vybráno i několik testovacích snímků pořízených z malých komerčně prodávaných hyperspektrálních kamer.

Testy algoritmů byly zaměřeny na přesnost odhadu endmembers. Na syntetických datech byl testován vliv šumu, počtu endmembers a také jaký má vliv přítomnost či nepřítomnost tzv. čistých pixelů (pure pixels). Jako kritérium byl vybrán spektrální úhel mezi odhadnutým a referenčním spektrem. V druhé části byly tyto algoritmy použity na analýzu reálných snímků, kde bylo sledováno, zda dokáží určit všechny obsažené materiály a s jakou odchylkou spektrálního úhlu.

Veškeré testování bylo provedeno v softwaru MATLAB (MATrix LABoratory).

2 Základy optiky

V této kapitole budou stručně popsány základní fyzikální zákonitosti z oblasti optiky, které souvisí s tématem spektroskopie.

2.1 Elektromagnetické záření


Elektromagnetické záření je jednou z forem přenosu energie prostorem. K přenosu energie dochází vlivem elektrického a magnetického pole. Elektromagnetické záření může být (v každém lineárním prostředí) považováno jako superpozice mnoha elektromagnetických vln různých vlnových délek. [1]

Rovinná elektromagnetická vlna se projevuje jako příčné postupné vlnění vektorů elektrického (\mathbf{E}) a magnetického (\mathbf{H}) pole. Přičemž platí, že tyto vektory jsou vzájemně na sebe kolmé a zároveň jsou oba kolmé na směr šíření vlny (vlnový vektor \mathbf{k}). Vlna se šíří ve vakuu rychlostí $c = 299\,792\,458\text{ ms}^{-1}$ (přibližně $3 \cdot 10^8\text{ ms}^{-1}$), v obecném prostředí dosahuje elektromagnetická vlna rychlosti v . [2]

$$c = \frac{1}{\sqrt{\epsilon_0 \mu_0}} \quad (1)$$

$$v = \frac{1}{\sqrt{\epsilon \mu}} = \frac{1}{\sqrt{\epsilon_r \epsilon_0 \mu_r \mu_0}} \quad (2)$$


Kde ϵ je elektrická permitivita, μ značí magnetickou permeabilitu. Index 0 vyjadřuje konstanty vakua ($\epsilon_0 = 8,85 \cdot 10^{12}\text{ Fm}^{-1}$, $\mu_0 = 4\pi \cdot 10^{-7}\text{ Hm}^{-1}$) a index r označuje relativní hodnoty daného prostředí. [2]



Obr. 1 - elektromagnetická vlna znázorněná v kartézských souřadnicích, vektory \mathbf{E} , \mathbf{H} leží v rovině os x a y , vektor \mathbf{k} směřuje ve směru osy z . [2]

2.2 Elektromagnetické spektrum

Elektromagnetické záření ve volném prostoru představuje superpozici rovinných elektromagnetických vln různých vlnových délek, různých směrů šíření (tzn. různých orientací vlnových vektorů \mathbf{k}) a různých polarizací. Charakteristické frekvenční vlastnosti elektromagnetického záření jsou dány množinou frekvencí vln (resp. vlnových délek). Takovou množinu nazýváme elektromagnetické spektrum. V závislosti na vlnových délkách rozlišujeme více druhů záření (viz obrázek níže). [1]



Obr. 2 - elektromagnetické spektrum [3]

Pouze nepatrná část elektromagnetického záření je rozeznatelná lidským okem. Jedná se o množinu vlnových délek v přibližném rozsahu 380–760 nm, tuto množinu nazýváme viditelné světlo. V elektromagnetickém spektru se viditelné světlo nachází mezi oblastmi ultrafialového záření (UV) a infračerveného záření (IR). Různé vlnové délky viditelného záření jsou vnímány lidským okem jako rozdílné barvy. [3]

2.3 Disperze záření


Při dopadu elektromagnetického záření na optické rozhraní dvou prostředí dochází kromě lomu záření také k jeho disperzi neboli rozkladu. Tento jev lze nejlépe znázornit na rozkladu bílého světla (světlo obsahující všechny vlnové délky z viditelné oblasti), kde průchodem optického rozhraní dochází k oddělení barevných složek (lom pod různými úhly). Příkladem disperze bílého světla je duha, kde dochází k rozkladu slunečního světla na kapičkách vody. [4]

Tento jev je způsoben závislostí rychlosti šíření vlny na vlnové délce. S rostoucí vlnovou délkou roste i rychlost šíření vlny. Záření s odlišnou rychlostí se na optickém rozhraní dvou prostředí lámou pod jiným úhlem, a tak dochází k disperzi záření. [4]

2.3.1 Optický hranol

Optický hranol (anglicky prism) je obvykle trojboký (nebo i víceboký) hranol nejčastěji vyrobený ze skla, ve kterém se využívá vícenásobného lomu na několika optických rozhraních za účelem rozkladu elektromagnetického záření (v oblasti viditelného světla a přilehlých vlnových délek) na jednotlivé složky. Rozklad se využívá při konstrukci spektrometru a jeho užití při spektrální analýze daného zdroje záření. [5]

Na vstup soustavy (jeden z boků hranolu) se přivádí úzký svazek rovnoběžných paprsků, jehož spektrum chceme zobrazit. Na optických rozhraních mezi vnější a vnitřní částí hranolu (obvykle rozhraní vzduch-sklo a sklo-vzduch) dochází k lomu. Při každém lomu dochází k disperzi záření a s každým následujícím lomem se zvětšuje úhel mezi jednotlivými složkami. Proto lze na výstupu (zobrazení pomocí matnice nebo obrazového senzoru) čitelně pozorovat jednotlivé barevné složky oddělené z původního záření. [6]



Obr. 3 - fotografie optického hranolu a znázornění principu rozkladu světla [7]

2.4 Difrakce

Difrakce, neboli ohyb světla je jev, který vychází z Huygensova principu a vlnové podstaty optického záření. Z Huygensova principu plyne, že každý bod vlnoplochy lze považovat za zdroj elementárního vlnění, vlnoplocha v dalším časovém okamžiku je vnější obalová plocha všech elementárních vlnoploch. [8] [9] Ohyb světla nastává při průchodu překážkou. Vlna se nešíří přímočaře, ale v závislosti na vlnové délce a rozměrech překážky se může dostat i do oblasti geometrického stínu (oblast která kopíruje tvar překážky). [10]

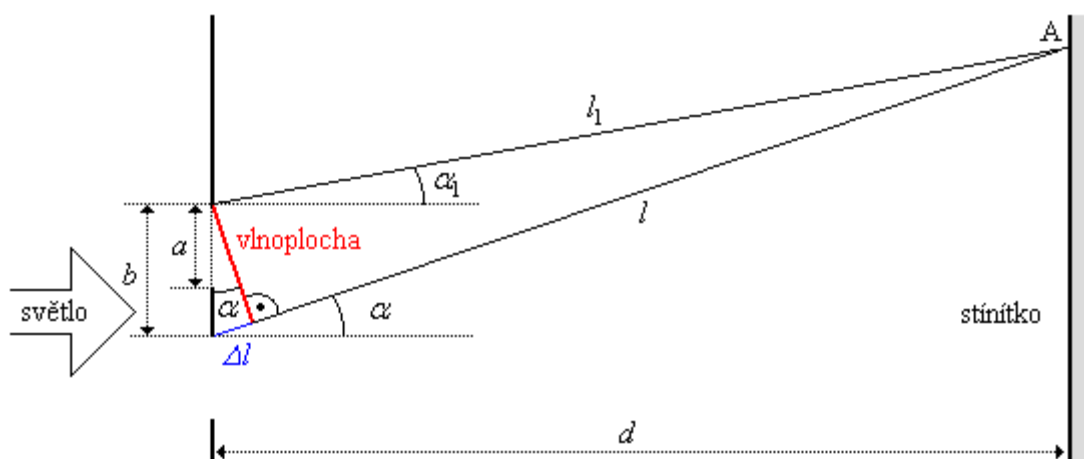
2.4.1 Difrakční mřížka

Difrakční mřížka (diffraction grating) umožňuje oddělit jednotlivé složky záření (oblast UV až část IR). [11] Na rozdíl od optického hranolu se zde využívá principu difrakce. Mřížka se skládá z pravidelné struktury štěrbin (velmi malých otvorů) nebo odrazných vrypů umístěných v malé vzdálenosti od sebe. Vzdálenost mezi štěrbinami b se nazývá mřížková konstanta a obvykle dosahuje hodnot řádově jednotky nebo desetin mikrometrů. [11] [12]

Na každé štěrbině dochází k ohybu záření, proto lze každou štěrbinu považovat za bodový zdroj elementárních vln. Výstup difrakční mřížky je sledován ve vzdáleném poli od jejího povrchu (Fraunhoferův limit) na stínítku nebo prostřednictvím obrazového senzoru. Mezi vlnami pocházejících z jednotlivých štěrbin dochází k interferenci (jejich vzájemné ovlivňování, vlny se zesilují nebo naopak ruší). Vzájemnou interferencí vln vzniká tzv. interferenční obrazec, na kterém jsou viditelná interferenční maxima. Tato maxima vznikají v místech na stínítku, ve kterých se vzdálenost od jednotlivých štěrbin liší o celočíselné násobky vlnové délky daného vlnění. Tento vztah je vyjádřený v rovnici 3. [9] [12]

$$b \cdot \sin \alpha = k \cdot \lambda \quad (3)$$

Kde b vyjadřuje vzdálenost štěrbin od sebe a výraz $b \cdot \sin \alpha$ (na obrázku níže vyznačený jako Δl) je rozdíl jednotlivých vzdáleností od štěrbin do konkrétního bodu na stínítku. Tento rozdíl by měl být roven celočíselnému násobku vlnové délky, tedy $k \cdot \lambda$. Číslo k vyjadřuje řád maxima. [12]




Obr. 4 - Znárodnění dvou štěrbin na difrakční mřížce a závislosti rozdílu jejich vzdáleností od bodu interferenčního maxima na stínítku. [13]

Podoba interferenčního obrazce je závislá na počtu štěrbin v pravidelné mřížce.


Na obrázku 5 je znázorněn průběh amplitudy interferenčního obrazce na ploše stínítka v závislosti na počtu štěrbin N . Červenou přerušovanou čarou je znázorněný obrazec difrakce na jediné štěrbině. Z grafů je zřejmé, že s rostoucím počtem N dochází k potlačení amplitudy v místech mimo interferenční maxima. Tohoto jevu se s výhodou využívá pro měření spektra záření, jelikož poloha interferenčních maxim je závislá na vlnové délce. [9]

Na stínítku se zobrazí spektrum daného záření v každé oblasti prvního a vyšších řádů maxim (s výjimkou nultého řádu). [9] Ve spektroskopii se převážně využívá spektra v maximu prvního řádu. [12]



Obr. 5 - průběh amplitudy interferenčního obrazce na ploše stínítka v závislosti na počtu štěrbin N , pro: a) $N = 2$, b) $N = 5$, c) $N = 10$, d) $N = 100$. [9]

Difrakční mřížky nachází široké uplatnění v oblasti spektroskopie. Existuje vícero možností jejich konstrukce, na obrázku 6 jsou znázorněny často používané metody. Tyto metody lze rozdělit na dvě hlavní skupiny v závislosti na tom, zda zobrazované záření prochází difrakční mřížkou (obr. 6a, transmission grating) nebo zda dochází k odrazu na povrchu mřížky (obr. 6b,c,d, reflective grating). Na obrázcích 6c a 6d je znázorněno, jakým způsobem lze upravit povrch odrazné mřížky, aby bylo dosaženo požadovaných vlastností (6c blazed grating – maximální účinnost v konkrétním řádu maxima, 6d holographic grating – pro citlivější měření). [14]



Obr. 6 - Možnosti konstrukce difrakční mřížky [14]

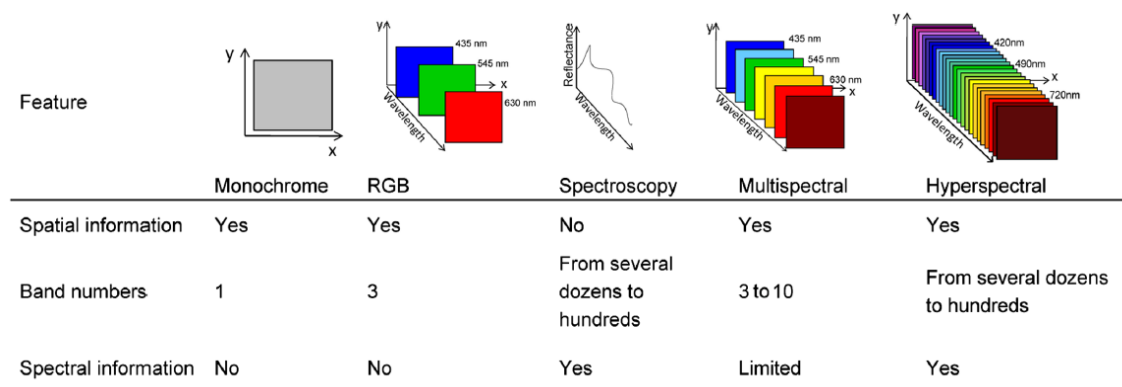
3 Zobrazování v prostoru (x, y) a ve spektru (λ)

Rozlišujeme několik možných přístupů k zobrazování. Podle způsobu zpracování prostorové a spektrální informace jej lze rozdělit do tří kategorií.

Do první skupiny patří standardní fotoaparáty nebo kamery. Tato zařízení zaznamenávají pouze prostorovou informaci o jasů zaznamenaného obrazu (2D prostor s prostorovými souřadnicemi x a y). V takovém případě se jedná o monochromatickou (černobílou) fotografii. U barevného snímání se využívá rozdělení viditelného spektra a záznamu do tří barevných složek (RGB), ale vzhledem k širce pásem jednotlivých barevných složek a omezení pouze na viditelnou část spektra lze považovat barevné snímání jako zobrazování s minimální spektrální informací.

Druhou kategorií je spektroskopie, která představuje odlišný přístup k zobrazování. Tato kategorie nezaznamenává prostorovou informaci, ale je zde kladen důraz na záznam informace spektrální.

V poslední kategorii jsou takové přístupy k zobrazování, kde je snaha zaznamenat dohromady prostorovou i spektrální informaci. Do této skupiny patří multispektrální zobrazování, ve kterém je spektrální informace zaznamenaná v několika (3-10) širších spektrálních pásmech. Hyperspektrální zobrazování je novější technologií, která umožňuje zaznamenat až stovky úzkých, na sebe navazujících spektrálních pásem. [15]



Obr. 7 - Možnosti zobrazování prostorové a spektrální informace [15]

Jednotlivé kategorie jsou podrobněji popsány v následujících kapitolách: standardní 2D zobrazování (3.1), spektroskopie (3.2), multispektrální zobrazování (3.3) a hyperspektrální zobrazování (kapitola 4).


3.1 Standardní 2D zobrazování

Fotoaparáty nebo kamery zachycují snímanou scénu tak, aby výsledný obraz barevně odpovídal lidskému vidění, respektive tak, aby zachycené spektrum odpovídalo spektrální citlivosti lidského zraku.

Hlavní částí digitálních fotoaparátů je obrazový senzor. Senzor se skládá z matice světlocitlivých buněk, kde dochází k přeměně intenzity dopadajícího záření na elektrický náboj. Samotný senzor je citlivý pouze na jas světla, nerozlišuje barevnou informaci. K získání barevného obrazu se využívá rozkladu světla do tří barevných složek (pásma vlnových délek pokrývající modré, zelené a červené spektrum viditelného světla). [16]

U většiny jednočipových zařízení se k barevnému rozkladu využívá bayerova maska. Tato maska se umísťuje před senzor a skládá se ze tří druhů barevných filtrů (RGB filtry) uspořádaných v pravidelné mřížce (využívá se dvojnásobný počet zelených filtrů pro větší citlivost lidského oka na tuto barvu). Na každou buňku senzoru tak dopadá pouze světlo jedné barvy (rozsah vlnových délek odpovídající dané barvě). Tímto způsobem je na senzoru zaznamenána informace ve třech barevných kanálech. Každý z těchto kanálů obsahuje informaci o příslušné barvě pouze v buňkách s odpovídajícím barevným filtrem. Pro doplnění barevné informace do prázdných buněk se používá interpolace, tedy dopočítání přibližné hodnoty. Zpravidla se využívá průměrování z okolních buněk v daném barevném kanálu. [17]

Spektrální citlivost obrazového senzoru je širší než citlivost lidského oka, z toho důvodu se před senzor umísťují další filtry zamezující průchodu ultrafialového (UV) a infračerveného (IR) záření. Na obrázku 8 jsou znázorněny hlavní části fotoaparátu, které ovlivňují vlastnosti optického paprsku před dopadem na obrazový senzor. Kromě zmiňovaných filtrů je součástí optické části ještě objektiv sloužící k zaostření obrazu a u některých zařízení se využívá ještě dvojice low-pass filtrů zamezujících vzniku vady moiré. [18]

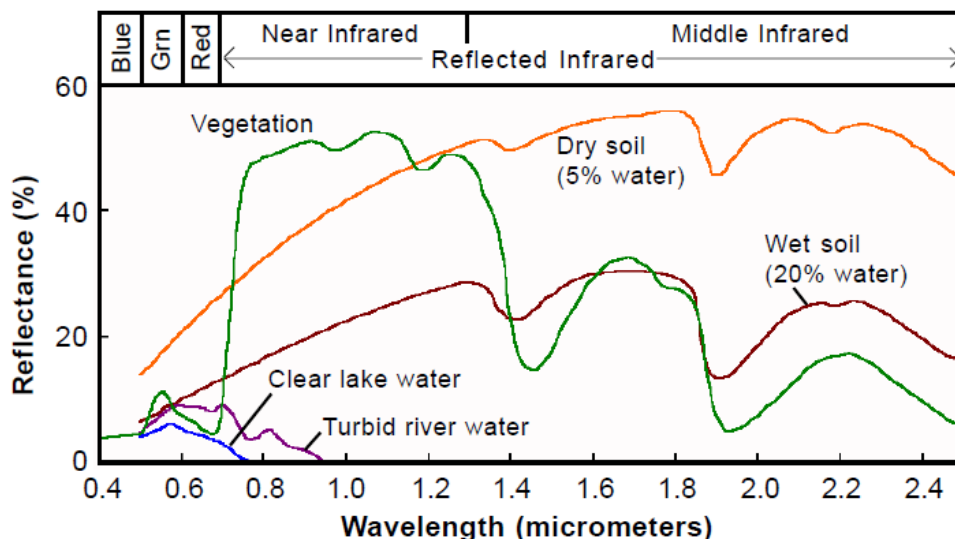


Obr. 8 - hlavní části fotoaparátu nebo kamery ovlivňující vlastnosti optického paprsku před dopadem na obrazový senzor. [18]

3.2 Spektroskopie

Spektroskopie je vědecký obor zabývající se analýzou elektromagnetického záření. Tato analýza spočívá v měření spektra (velikosti energie elektromagnetického záření v závislosti na vlnové délce). Informace o spektru může být využita k zobrazení spektrálních charakteristik zdrojů záření nebo ke studii interakce mezi zdrojem záření a testovaným materiálem. [19]

Každý materiál reaguje odlišně na různé vlnové délky. Této skutečnosti se využívá ve spektroskopii za účelem definování spektrálních vlastností nebo identifikace jednotlivých materiálů podle jejich spektrálních znaků. [20] Na povrchu materiálu může docházet, v závislosti na vlnové délce, k odrazu (do různých úhlů), pohlcení nebo k průchodu elektromagnetického záření. [21] V závislosti na tom, zda sledujeme elektromagnetické záření odražené od materiálu nebo záření, které materiálem projde rozlišujeme zda jsme měřili spektrum odraženého záření (reflectance spectrum) nebo záření procházející materiálem (transmissive spectrum). [19] [20]



Obr. 9 - spektrální křivky (reflectance curves) pro výběr několika běžných materiálů na zemském povrchu. Zobrazeny v rozsahu vlnových délek viditelného a části infračerveného záření. [21]


Na obrázku 9 jsou pro ilustraci zobrazena typická spektra běžných povrchů země (vegetace, zemina, voda). Odrazivost (reflectance) na ose y vyjadřuje poměr odražené energie elektromagnetického záření ku energii dopadající na testovaný materiál. Oblasti nízké odrazivosti (jako je např. pásmo blízko 1,4 μm pro vegetaci) odpovídají pásmům vlnových délek, u kterých dochází k vysoké absorpci energie sledovaného materiálu. Na základě průběhu reflektance, pozice a velikosti absorpčních pásem lze rozlišovat rozdílné materiály. [21]

Tvar spektrálních křivek závisí na vlastnostech materiálu. Například u neorganických materiálů je křivka reaktance ovlivněna chemickým složením a krystalovou strukturou. Reaktance rostlin je ovlivněna např. strukturou listů, obsahem vody nebo chlorofylu. U zelených rostlin chlorofyl efektivně absorbuje viditelné záření, ale pohlcuje silněji modré a červené části oproti zelenému spektru, proto je na spektrální křivce pro vegetaci na obrázku 9 viditelný peak v oblasti zeleného spektra (cca 0,54 μm). Z toho důvodu se nám zdravé rostliny jeví jako zelené a suché rostliny, které ztrácí vodu a chlorofyl, jsou zbarvené do žluta, červena či hněda v závislosti na jejich dalších vlastnostech. [21]

3.2.1 Spektrometr

Spektrometr je zařízení, které se využívá k měření rozložení spektrálních komponentů sledovaného záření a následnému zobrazení signálu tohoto záření jako funkce vlnové délky. [22] Spektrometry pracující v oblasti viditelného záření a části přilehlých oblastí UV a IR (pracovní oblast např. 200–1100 nm [23]) pracují na principu rozkladu elektromagnetického záření na jednotlivé složky vlnových délek. K tomuto rozkladu lze využít optický hranol nebo difrakční mřížku (v současné době se převážně používá difrakční mřížka [23] [24]).


Existuje několik konfigurací konstrukce spektrometru (Czerny-Turner, Fastie-Ebert Offner, aj. [25] [26]). Všechny tyto konstrukce vychází ze stejného základního schématu.



Obr. 10 - schéma zobrazující základní princip spektrometru [27]

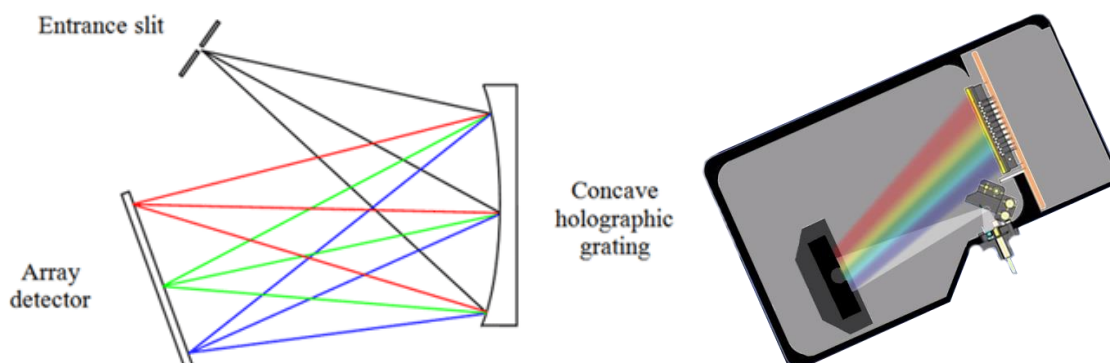
Pro přivedení sledovaného elektromagnetického záření na vstup spektrometru se využívá optického vlákna. Na vstupu spektrometru prochází záření štěrbinou, která redukuje jeho

množství. Za štěrbinou vzniká divergentní záření, které následně prochází kolimační optikou (konkávní zrcadlo nebo čočka), která vytváří z daného záření kolimovaný svazek. Tento svazek je nasměrován na difrakční mřížku. Na povrchu mřížky dochází k rozkladu záření do pásem odpovídajícím jednotlivým vlnovým délkám. Výběrem technologie a parametrů difrakční mřížky (počet vrypů, jejich vzájemná vzdálenost, aj.) lze určit rozsah pracovní oblasti spektrometru. Záření rozložené do spektrálních komponentů je následně nasměrováno zaostřovací optikou na odpovídající místo na obrazovém senzoru podle vlnových délek. Zde dochází k převodu na elektrický signál, digitalizaci a odeslání do vyhodnocujícího zařízení. [22] [23] [28]



Obr. 11 - Princip Crossed Czerny-Turner Spectrometru [29] a ukázka možné konstrukce [23]

K výrobě komerčních vláknových spektrometrů se často využívá konfigurace Czerny-Turner, například ve variantě, kde se kříží jednotlivé optické cesty (crossed), jak je zobrazeno na obrázku 11. Další možností je využití konkávní holografické mřížky (viz obrázek 12), která umožňuje rozklad záření a zároveň zaostření na detektor. Díky tomu lze redukovat množství optických elementů. Tato konfigurace umožňuje potlačení některých optických vad přítomných u předchozí metody. [29]



Obr. 12 - Princip spektrometru s holografickou mřížkou [29] a ukázka možné konstrukce [30]


3.3 Multispektrální zobrazování

Spektrometry popsané v předchozí části umožňují proměření spektra daného záření s velmi přesným spektrálním rozlišením, avšak neposkytují žádnou informaci, jak se zaznamenané záření mění v prostoru. Z toho důvodu se začali vyvíjet nové technologie zobrazování, ve kterých je na úkor spektrálního rozlišení (mnohem méně spektrálních pásem s podstatně větší šířkou) zachycena také informace o tom, jak se spektrum daného záření mění v prostoru. Obecně se toto odvětví, zabývající se zpracováním spektrální i prostorové informace, nazývá zobrazovací spektroskopie nebo spektrální zobrazování (imaging spectroscopy / spectral imaging). [31] Multispektrálním zobrazováním jsou označovány metody, které umožňují zaznamenat několik (3-10) širokých spektrálních pásem. [15]

Jedním z možných přístupů multispektrálního zobrazování je rozdělení paprsku záření pomocí optických prvků a záznamu na několik obrazových senzorů (multispectral beamsplitting), tedy využití obdobného způsobu jako se využívá u třísenzorového záznamu barevného obrazu u standartního zobrazování. [31]

Na obrázku níže jsou zobrazeny dvě možné metody rozdělení záření na jednotlivé složky. Vlevo je znázorněn přístup používající barvo-dělicí hranol, který využívá rozdílného indexu lomu pro různé vlnové délky elektromagnetického záření. Tento hranol se skládá z více skleněných částí, mezi kterými jsou tenké vzduchové mezery. Na každém rozhraní sklo-vzduch dochází k odrazu záření daných vlnových délek. [32] Vzhledem ke složité struktuře hranolu bylo dosaženo limitu při rozdělení na 4 spektrální kanály. [31]

Druhá metoda, zobrazená na obrázku vpravo, využívá soustavu polopropustných zrcadel s nanesenými barevnými filtry. [32] Ačkoliv se jedná o jednodušší konstrukci, tak i tento přístup má své limity. Hlavní nevýhodou je prostorový limit a kumulativní ztráty propustnosti na spektrálních filtrech. Z toho důvodu je tato metoda vhodná pro rozdělení maximálně do pěti nebo šesti spektrálních pásem. [31]



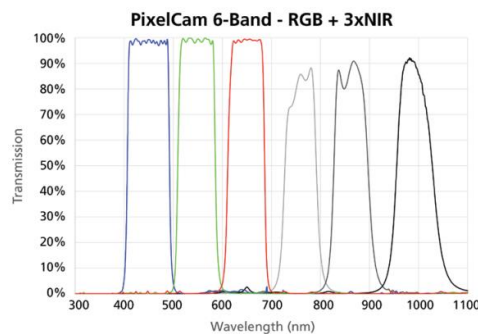
Obr. 13 - Multispectral beamsplitting, barvo-dělicí hranol (vlevo), soustava polopropust. zrcadel (vpravo) [31]

Další způsob jak zaznamenat multispektrální data je založen na postupném (děleném v čase) snímání obrazu v jednotlivých spektrálních pásmech (Staring). Tento způsob v každém časovém okamžiku snímá obraz pouze ve zvoleném spektrálním pásmu. Princip takové multispektrální kamery spočívá v záznamu vyfiltrovaného pásma záření na monochromatickém obrazovém snímači. K výběru konkrétního spektrálního rozsahu jsou využity optické filtry. Existuje více možností, jak dosáhnout přeladění mezi jednotlivými spektrálními pásmy. Například lze využít filtrového kola obsahujícího upevněné spektrální filtry, lineárně variabilního filtru nebo přeladovaného filtru. [15] Nevýhodou takovýchto kamer jsou větší prostorové nároky, jelikož jejich součástí musí být systém na přeladování filtrů, a také časová závislost snímání. [15] [33]



Obr. 14 - Porovnání konstrukce staring multispektrální kamery s filtrovým kolem (136 x 124 x 105 mm) [34] a snapshot multispektrální kamery s mozaikovou strukturou filtru (52,5 x 52,5 x 79,4 mm) [35]

Multispektrálního obrazu lze také dosáhnout podobně jako u standardního zobrazování s jedním obrazovým senzorem, kde se využívá bayerovi masky. Hlavním principem je vhodná kombinace mřížky spektrálních filtrů a řady mikročoček. Taková metoda multispektrálních kamer umožňuje záznam dat v jediném časovém okamžiku, resp. za jedinou dobu expozice a proto se řadí k tzv. snapshot metodám. Tato metoda se využívá i v hyperspektrálním zobrazování, a proto bude detailněji popsána až v další kapitole. [15]




Obr. 15 - Ukázka spektrální charakteristiky snapshot kamery zobrazené na obrázku 14 vpravo [35]

4 Hyperspektrální zobrazování

S rozvojem techniky zobrazovací spektroskopie přicházejí nové přístupy, které poskytují mnohem lepší spektrální vlastnosti oproti multispektrálnímu zobrazování (větší počet spektrálních pásem, užší pásma navazující na sebe). Tato kategorie se označuje jako hyperspektrální zobrazování (HyperSpectral Imaging = HSI).


Hyperspektrální kamera umožňuje zaznamenat prostorovou informaci (2D obraz) a zároveň informaci o spektrálním složení záření dopadajícího na jednotlivé pixely senzoru. Zaznamenaná spektra se skládají z desítek až stovek úzkých pásem vlnových délek.



Obr. 16 - základní princip hyperspektrální kamery [20]

4.1 Datacube

Výstupní data hyperspektrální kamery jsou označována jako datacube. Skládají se z informace o prostoru (dvě prostorové dimenze x a y) a z informace o spektrálním rozložení obrazu vyjádřené ve směru osy z (každá hodnota na ose z odpovídá jednomu spektrálnímu pásmu). [36]



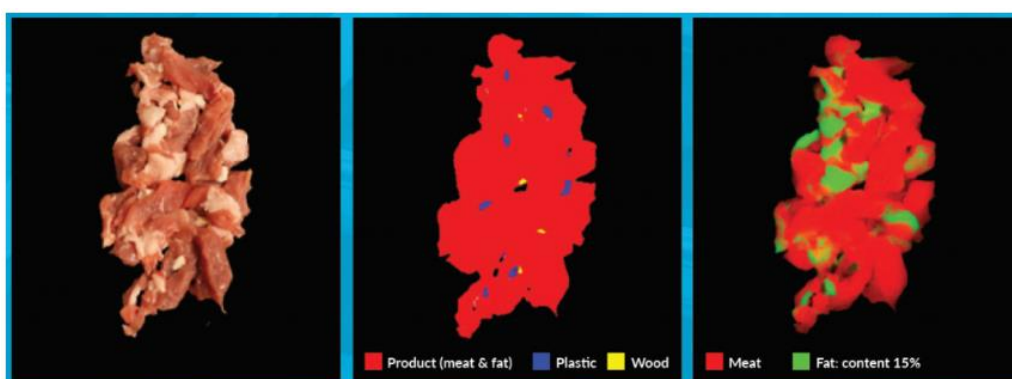
Obr. 17 - znázornění datacube (prostorové dimenze x, y a informace o spektru λ) [31] [37]

Tato data mohou být reprezentována buď jako sada snímků, kde každý snímek odpovídá konkrétní vlnové délce (spektrálnímu pásmu) nebo jako sada spektrálních charakteristik pro každý pixel. [37]

4.2 Využití a aplikace hyperspektrálního zobrazování

Vysoké spektrální rozlišení hyperspektrálních kamer umožňuje jejich využití k identifikaci materiálů pomocí spektroskopické analýzy. Proto se hyperspektrální snímání využívá v různých oborech vědy i průmyslu, kde není možné využití klasické spektroskopie. [61] Obecně lze aplikace HSI rozdělit na dvě odlišné skupiny.

První skupinou využití hyperspektrálních kamer je snímání převážně v prostorách laboratoří nebo průmyslových hal, využívající malé komerční kamery. Sledování materiálů, resp. látek obsažených v materiálech, má značné využití v potravinářském průmyslu, kde se hyperspektrální kamery používají k inspekci kvality nebo k třídění potravin. Sledování odraženého spektra umožňuje detekci znehodnocených či kontaminovaných produktů (například v mase se mohou objevit paraziti, částičky plastů, dřeva nebo i kovů), kontrolu zralosti, čerstvosti a spousty dalších kvalitativních parametrů. [38] [39]




Obr. 18 - ukázka detekce cizích objektů v mase a detekce množství tuků [38]

Výhodou HSI technologie v této oblasti je možnost použití automatizovaného systému vyhodnocujícího výsledky v reálném čase, kde se nedestruktivní metodou (optické měření) sledují všechny produkty. [40] Takovéto systémy lze využít i v jiných odvětvích průmyslu za účelem třídění nebo kontroly parametrů, například třídění odpadu na páse (rozlišení kovů, plastů, atd.) nebo kontrola barvy (jas, sytost a tón) v průmyslové výrobě aut. [41] Dalšími odvětvími s rozšířenou aplikací hyperspektrálních kamer jsou biotechnologie a užití v medicíně, kde se HSI využívá např. k selekci životaschopných semen rostlin nebo k detekci rakoviny kůže a charakterizaci jiných zranění. [42] [43] Zajímavou aplikací je také využití HSI v oblasti forenzní analýzy. Hyperspektrální snímání umožňuje detekovat krev a určit, jak je krvavá stopa stará. Obdobně lze také detekovat stopy po střelbě a pomocí analýzy snímku určit


přibližnou vzdálenost a úhel od místa střelby. Další možností je ověřování pravosti dokumentů nebo podpisů. Výhodou oproti standardním forenzním chemickým metodám je rychlost, nekontaktnost a nedestruktivita hyperspektrálního snímání. [44]

Do druhé skupiny patří letecké nebo vesmírné snímání. Aplikace z této kategorie pasivně snímají sluneční paprsky odražené od objektů na povrchu země a vyhodnocují jejich odrazivost v požadované spektrální oblasti. K tomu využívají hyperspektrální kamery umístěné na palubě letadel (airborne remote sensing) nebo satelitů (spaceborne remote sensing). [45]



Obr. 19 - Základní princip dálkového pasivního snímání satelitem (spaceborne remote sensing) [45]

Dálkové snímání hyperspektrálními kamerami se využívá v precizním zemědělství, kde jej lze využít k identifikaci a lokalizaci plevelů nebo škůdců, sledování zdraví rostlin nebo k hodnocení jejich zralosti. [42] [46] Na základě změřených dat lze také řídit variabilní dávkování hnojiva. [47] Remote sensing nachází další využití v oblasti monitorování životního prostředí. Zde se využívá ke sledování šíření znečišťujících látek, například ke sledování šíření škodlivých květů řas v jezeře [48] nebo v lesnictví k měření škod způsobených chorobami rostlin. [49] Existuje mnoho dalších specializovaných aplikací využívající airborne nebo spaceborne remote sensing.

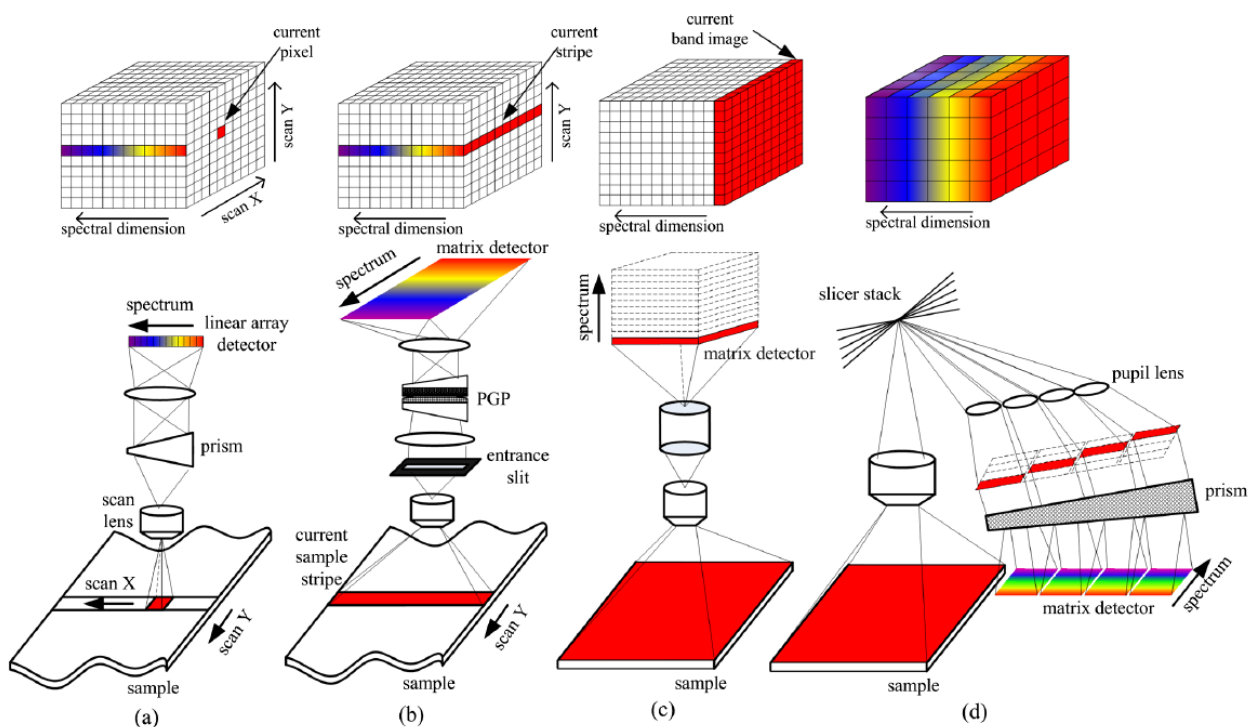


Obr. 20 - analýza HSI dat v precizním zemědělství, na obrázcích je zobrazena detekce: a) plevelů, b) mezer ve výsadbě, c) škůdců [46]

4.3 Technologie hyperspektrálních kamer

Jak již bylo zmíněno v kapitole 3.3 hyperspektrální a multispektrální kamery patří společně do kategorie zobrazovací spektroskopie. Jejich vzájemný rozdíl je v počtu a šířce zaznamenaných pásem. Avšak oboje tyto skupiny mohou vycházet ze stejné technologie. Z toho důvodu budou v této kapitole popsány obecně přístupy k dosažení zobrazovací spektroskopie.

Systémy zobrazovací spektroskopie lze rozdělit do 4 hlavních skupin podle způsobu jakým získávají datacube. Tyto metody jsou zobrazeny na obrázku 21 a budou postupně popsány v kapitolách 4.3.1 a 4.3.2.



Obr. 21 - Typické přístupy ke spektrálnímu zobrazování: a) whiskbroom, b) pushbroom, c) staring, d) snapshot [15]

4.3.1 Skenovací metody zobrazovací spektroskopie

Data poskytující informaci o třech dimenzích (x , y , λ) jsou velice obsáhlá. Proto jedním z možných způsobů k jejich získání je postupné skenování v čase. Skenovat lze více způsoby podle zvolené dimenze.

4.3.1.1 Bodové skenování (whiskbroom)

Bodové skenování je založeno na principu standardního spektrometru doplněného o optické prvky umožňující výběr specifického bodu snímané plochy.

Zrcátka postupně skenují snímanou plochu přes prostorové souřadnice (x, y). Ke skenování se využívá buď pohybu snímaného vzorku nebo detektoru. Záření z vybraného bodu je uvnitř spektrometru rozloženo na jednotlivé složky (λ) disperzní mřížkou nebo optickým hranolem a dopadá na řádkový snímač. [15]

Nevýhodou tohoto přístupu je náročná konfigurace hardwaru pro skenování ve specifických bodech. Další nevýhodou je veliká časová náročnost, vzhledem k potřebě skenování přes oboje prostorové dimenze. [15]

4.3.1.2 Řádkové skenování (pushbroom)

Na podobném způsobu jako předchozí metoda funguje i řádkové skenování. Oproti předchozí metodě je zde v jediném okamžiku skenovaný celý řádek snímané plochy naráz, a proto je zapotřebí skenování pouze přes jednu prostorovou dimenzi. Tato změna značně ulehčuje konstrukci, jelikož už není zapotřebí pohyblivých částí. Skenování přes prostorovou dimenzi je docíleno umístěním senzoru na rovnoměrně se pohybující platformu (dron, letadlo, satelit) nebo naopak snímáním rovnoměrně se pohybujícího objektu. Tato metoda se často využívá v oblasti leteckého nebo vesmírného snímání povrchu země. [31]

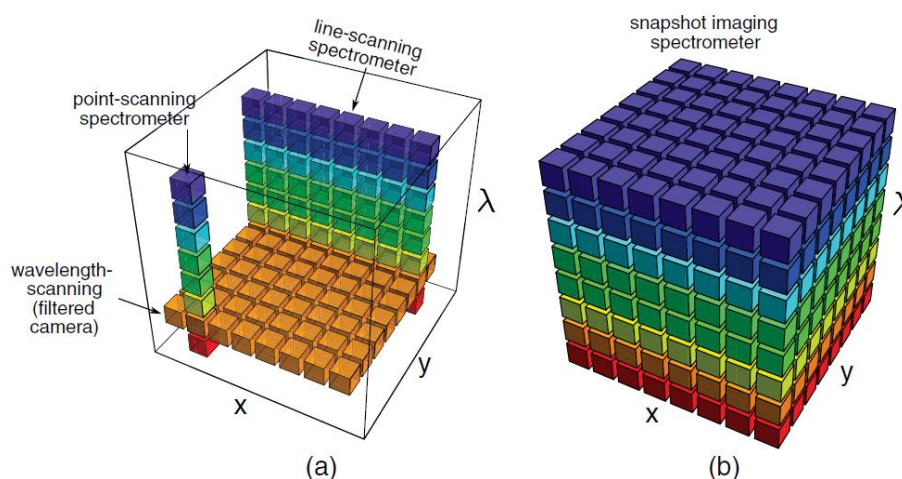
V konstrukci řádkového skeneru se využívá objektivu pokrývajícího celou šířku snímané plochy, přičemž snímané záření prochází následně úzkou štěrbinou, která umožňuje výběr jediného řádku snímané plochy. Toto záření je následně rozptýleno pomocí složitějšího disperzního členu PGP (Prism-Grating-Prism - kombinace dvou optických hranolů a difrakční mřížky) na 2D snímač, ve kterém je zachycena prostorová informace ve směru jedné osy a spektrální informace ve směru osy druhé. Celková datacube může být následně zaznamenána postupným skenováním jednotlivých řádků snímané plochy. [15]

Velikou výhodou oproti bodovému skenování je kromě robustnější konstrukce bez pohyblivých částí také větší světelná citlivost zajištěná delší expoziční dobou. Avšak musí být zajištěna přesná synchronizace snímání pohyblivé scény. [15]

4.3.1.3 Pásmová sekvenční metoda (staring)

Staring, neboli pásmová sekvenční metoda, funguje na trochu odlišném principu než metody předcházející. V této metodě se neskenují prostorové dimenze. Informace o prostoru je zachycená naráz, naopak se zde využívá postupného skenování ve spektrální oblasti. [15]

Princip této metody byl již popsán v kapitole 3.3 na straně 18. Základem je monochromatický senzor, zajišťující záznam prostorové informace (x, y) a přeladovatelné optické filtry pro získání informace spektrální (λ). [15]



Obr. 22 - Znárodnění jakou část datacube zaznamenávají jednotlivé metody za jednu expoziční dobu.
a) skenovací metody (bodové skenování, řádkové skenování a pásmová sekvenční metoda)
b) snapshot technologie spektrálního zobrazování. [31]

4.3.2 Snapshot technologie spektrálního zobrazování


Zařzení na principu snapshot (také se označují jako single-shot) nevyžadují žádné skenování snímané plochy. Rozdíl oproti předchozím metodám spočívá v tom, že celá datacube (x, y, λ) je pořízená v jediném okamžiku (za jedinou expozici). K tomu se využívá optická soustava, která přemapuje a rozptýlí obraz na obrazový snímač. Z toho důvodu je celkový počet buněk v datacube ($x \cdot y \cdot \lambda$) limitovaný počtem pixelů obrazového senzoru. [15]

Existuje několik způsobů jakými lze prostorově rozdělit záření dopadající na snímač tak, aby byly zaznamenány veškeré potřebné informace k sestavení datacube. V závislosti na použité metodě se odlišuje rozložení jednotlivých buněk datacube na ploše senzoru. Data zaznamenaná na senzoru jsou následně softwarově zpracovaná a uspořádaná do požadované podoby. [31]

4.3.2.1 Integral field spectroscopy (IFS)

V astronomii se nejčastěji používají metody snapshot spektrálního zobrazování založené na integraci záření. Tyto metody využívají umístění optického prvku do obrazové roviny snímaného objektu, kde dochází k rozdělení obrazu podle prostorového rozdělení. Optickým prvkem může být pole zrcadel (IFS-M), optických vláken (IFS-F) nebo čoček (IFS-L). [31]


IFS lze nejlépe popsat pomocí konstrukce zahrnující optická vlákna. Princip této metody je znázorněn na obrázku 23. V obrazové rovině se nachází koherentní svazek optických vláken. Do každého z optických vláken se integruje záření z oblasti, kterou pokrývá dané vlákno. Následně jsou optická vlákna tohoto svazku přeskupena tak, aby na jeho výstupu byla seřazena do jediné řady. Na výstupu svazku se využívá principu standardního spektrometru k rozložení záření z každého vlákna do spektra. Na obrazovém senzoru potom každý řádek odpovídá spektru konkrétního bodu snímané plochy. [31]



Obr. 23 - Princip IFS-F metody spektrálního zobrazování [31]

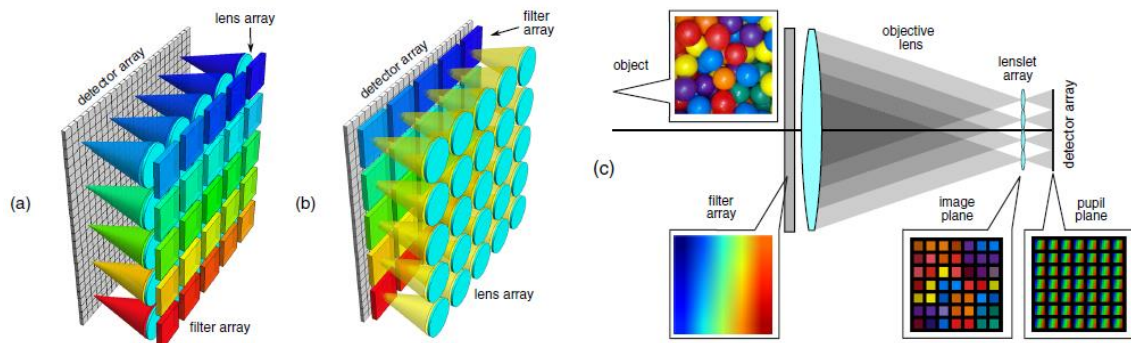
4.3.2.2 Multiaperture Filtered Camera (MAFC)

Další technologií snapshot spektrálního zobrazování je MAFC. Tato metoda je konceptuálně nejjednodušší. Její konstrukce je založena na kombinaci pole mikročoček a pole optických filtrů. Základní myšlenka této metody je zobrazena na obrázku 24. [33]



Obr. 24 - Základní princip MAFC spektrálního zobrazování [33]

Každá mikročočka rozděljuje obraz na tzv. jednotky (units). Jednotky zobrazují obraz odpovídající jejich prostorovému umístění. Výsledný obraz zaznamenaný na senzoru se skládá z menších obrazů odpovídajících jednotlivým čočkám, resp. jednotkám. Rozdělení spektrálních složek se dosáhne pomocí pravidelné matice spektrálních filtrů, přičemž každé mikročočce náleží jeden filtr. [31] [33] Podle pořadí jednotlivých komponentů (mikročočky, filtry a hlavní optika zařízení) lze rozlišit více přístupů k této metodě. Na obrázku 24 jsou zobrazené možné varianty. [31]



Obr. 25 - Varianty systémů MAFC spektrálního zobrazování [31]


4.4 Parametry Hyperspektrálních kamer

Parametry hyperspektrálních kamer závisí na zvolené technologii a požadované aplikaci. Nejdůležitější vlastnosti hyperspektrálních kamer vyjadřují prostorové a spektrální parametry. Mezi prostorové parametry patří velikost plochy snímaného obrazu, vzdálenost snímače od povrchu (typické parametry pro letecké nebo vesmírné snímání), a také prostorové rozlišení výsledné datacube. [50]

K nejdůležitějším spektrálním parametrům patří spektrální rozsah, tj. jak velkou část spektra je dané zařízení schopno zachytit. Obvykle se sledují vlnové délky z oblastí viditelného světla (0,38–0,76 μm), blízkého infračerveného záření (0,76–1,4 μm) nebo krátkých infračervených vln (1,4–3 μm). [45] Ale existují i speciální zařízení pro pokrytí delších vlnových délek, například společnost Specim pokrývá vlnové délky až do 12,4 μm . [51]

Také je důležitý počet zaznamenaných spektrálních pásem a šířka jednotlivých pásem (definováno parametrem FWHM). [43] Pro dosažení přesných výsledků jsou vyžadovány velmi malé šířky spektrálních pásem (typicky 15 nm a menší). Počet spektrálních pásem je omezený rozlišením snímače a konstrukčním řešením daného zařízení. Snapshot kamery zaznamenávají méně spektrálních pásem (maximálně dohledáno 125 pásem při šířce pásem 4 nm [53]) oproti

skenovacím metodám (maximálně dohledáno 447 pásem při šířce pásem 1,3 nm [55]). Z těchto parametrů plyne, že jediné konstrukční řešení hyperspektrální kamery umožňuje pokrýt pouze část zmiňovaných spektrálních rozsahů (viz obrázek níže).



Obr. 26 - Spektrální rozsahy jednotlivých hyperspektrálních kamer od výrobce Resonon [56]

Tabulka 1: Porovnání parametrů vybraných komerčně vyráběným HSI kamer [52][53][54][55]

Název	XIMEA Snt32 NIR	Fireflye S185 SE	SPECIM FX50	Pika XC2
Výrobce	Ximea, Imec	Cubert	Specim	Resonon
Zdroj	[52]	[53]	[54]	[55]
Technologie	Snapshot	Snapshot	Linescan	Linescan
Prostorové parametry:				
prostorové rozlišení [px]	256 x 256	50x50	640 x ds*	1600 x ds*
Spektrální parametry:				
spektrální rozsah [μm]	0,6 - 0,97	0,45 - 0,95	2,7 - 5,3	0,4 - 1
počet spektr. Pásem [-]	32	125	154	447
šířka pásem [nm]	< 10	4	35	1,3
parametry kamery a záznamu:				
velikost datacube	256 x 256 x 32	50x50x125	640 x ds* x 154	1600 x ds* x 447
rychlost snímání [cube/sec]	120	15	-	-
rychlost snímání [lines/sec]	-	-	380	165
detektor	CMOS	Si CCD	neuveđeno	neuveđeno
bitová hloubka	10	12	16	12

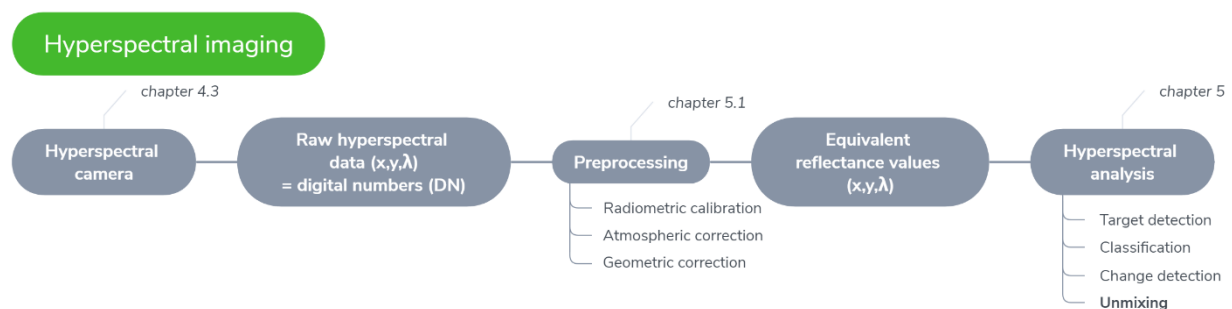
* ds = délka skenování

5 Analýza hyperspektrálních dat

Hyperspektrální zobrazování nachází mnohé využití v různých oblastech vědy či průmyslu (viz kapitola 4.2). Každá z těchto oblastí může využívat odlišných přístupů k analýze hyperspektrálních dat. V současnosti je výzkum analýzy HSI nejvíce zaměřen na: detekci známých či neznámých cílů v dané scéně (target detection), klasifikaci oblastí snímané scény, ve kterých dominuje konkrétní materiál (classification), detekci změn ve snímané scéně za periodu času (change detection) a získání hlavních složek (endmembers) a jejich rozložení na snímané scéně (unmixing). [45] Všechny tyto oblasti analýzy hyperspektrálních dat jsou aktivně zkoumány a ke každé bylo již navrženo nespočet metod a přístupů. Tato práce je zaměřena na poslední zmiňovanou oblast, tedy hyperspectral unmixing (HU).

Hyperspektrální zobrazování vychází z kombinace standardního zobrazování a spektroskopie (viz kapitola 4). HSI data mají podobné prostorové charakteristiky jako standardně pořízené snímky či videa a podobné spektrální charakteristiky jako spektrum pořízené spektrometrem (vysoká korelace mezi sousedními pixely a vlnovými délkami). Z toho plyne, že k analýze hyperspektrálních dat by mělo být možné využít již existující prostředky a metody, resp. jejich modifikace. Avšak existuje několik faktorů, které činí analýzu HSI dat obtížným úkolem, který vyžaduje sofistikované metody a algoritmy. Mezi tyto faktory patří velikost a vysoká dimenzionalita HSI dat, degradační mechanismy ovlivňující data při jejich pořizování (šumy a atmosferické efekty) a spektrální míchání (spectral mixing). [50]

Na obrázku 27 je znázorněný základní řetězec hyperspektrálního zobrazování. Na surová (raw) data pořízená hyperspektrální kamerou je nejprve aplikována kalibrace dat (preprocessing – viz následující kapitola). Poté je možné, podle požadovaného využití, použít některou z metod analýzy hyperspektrálních dat.

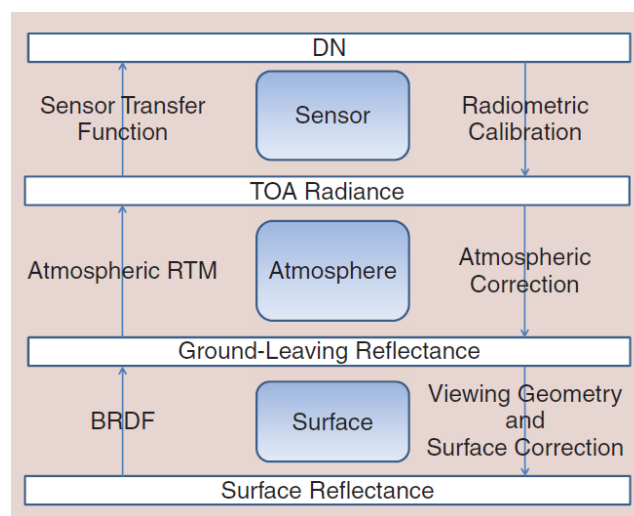


Obr. 27 - Základní řetězec zpracování hyperspektrálních dat

5.1 Preprocessing (konverze změřené radiance na odpovídající reflektanci)

Pro přesnou analýzu hyperspektrálních dat je zapotřebí změřit s co největší přesností spektrální odrazivost (spectral reflectance). Tento parametr odpovídá poměru energie odraženého záření (od snímané scény) ku energii záření dopadajícího (na snímanou scénu) a je vyjádřen jako funkce vlnové délky. Před zaznamenáním tohoto záření dochází ke zkreslení jeho hodnot vlivem několika jevů, a proto hodnoty zaznamenané na jednotlivých buňkách hyperspektrální kamery neodpovídají spektrální reflektanci snímané scény a je nutná jejich kalibrace. Mezi jevy způsobující toto zkreslení patří: spektrum zdroje záření, interakce tohoto záření s atmosférou, geometrie snímané scény a charakteristika použité hyperspektrální kamery. [21]

Kalibrace zaznamenaných hodnot na senzoru, preprocessing, se realizuje postupnou konverzí těchto hodnot, dokud přibližně neodpovídají hodnotám spektrální reflektance. [21] Jednotlivé kroky této konverze jsou zobrazeny na obrázku 28 a budou popsány v následujících odstavcích. Tato konverze bude popsána pro airborne nebo spaceborne HSI, kde je více faktorů ovlivňujících zaznamenané hodnoty (atmosférické jevy a větší vliv zobrazovací geometrie a struktury povrchu).



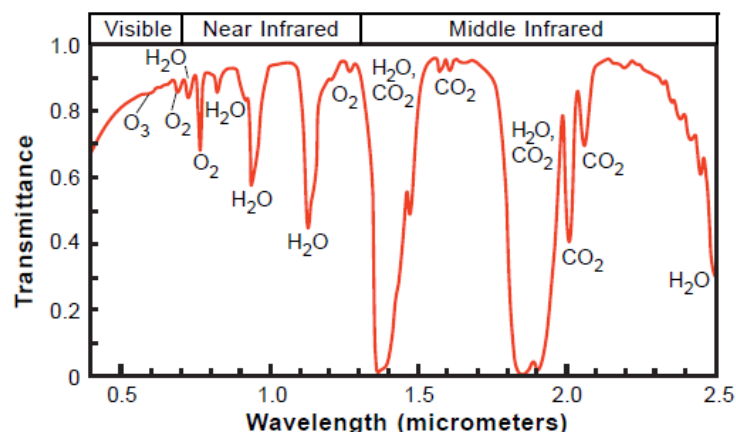
Obr. 28 - Schématické znázornění konverze hodnot HSI kamery před dalším zpracováním [50]

Výstupem hyperspektrálního senzoru jsou digitální hodnoty (Digital Numbers = DN), které neodpovídají skutečné hodnotě měřené veličiny. [50] Prvním krokem konverze je radiometrická kalibrace, která bere v potaz přenosovou funkci hyperspektrální kamery (Sensor Transfer Function) a převádí DN na hodnoty odpovídající množství dopadajícího světla na

senzor, tzn. spektrální radianci. [21] U této veličiny nebyly ještě eliminovány atmosférické jevy, a proto je označena jako radiance před senzorem nebo radiance nad atmosférou (Top Of Atmosphere = TOA). [50]

Dalším krokem je korekce atmosférických jevů. Energie slunečních paprsků procházejících atmosférou na povrch země a následně opačným směrem je na určitých vlnových délkách absorbována určitými plyny (H_2O , CO_2) a rozptýlena molekulami a částicemi plynů. Na obrázku 29 je znázorněna křivka atmosférické propustnosti za běžných atmosférických podmínek. Z ilustrace je patrné, že v některých pásmech vlnových délek dochází téměř k úplné redukci energie (absorbční pásma okolo 1,4 a 1,9 μm), proto lze v těchto pásmech zaznamenat pouze malé množství užitečné informace. [21]

Tvar křivky atmosférické propustnosti se může lišit i v rámci jediného snímku, jsou-li atmosférické podmínky rozdílné v prostoru nebo dochází-li k větším dráhovým rozdílům slunečních paprsků, způsobeným rozdílnou nadmořskou výškou snímané scény. [21] K atmosférické korekci se využívá inverze vytvořených modelů, které popisují tyto atmosférické jevy (Radiative Transfer Model = RTM). [50]



Obr. 29 - Závislost atmosférické propustnosti na vlnové délce, za atmosférických běžných podmínek [21]


V posledním kroku je korigován vliv iluminačního úhlu (úhel pod kterým dopadá sluneční záření) a zobrazovacího úhlu (úhel pod kterým je zobrazovaná snímaná oblast), a také vliv optických a strukturálních vlastností snímané scény (vlivem rozdílné struktury snímaného povrchu může docházet k odrazům do různých směrů). [50] [21] Odražené světlo na zemském povrchu je popsáno jako funkce příchozích a odchozích směrů šíření (Bidirectional Reflectance Distribution Functions = BRDF), tuto funkci lze ještě doplnit o komplexní model povrchové struktury. [50]

5.2 Zobrazení ve spektrálním prostoru

Jemné spektrální rozlišení a veliký objem hyperspektrálních dat představuje výzvu při jejich analýze. Zaznamenaná spektra se standardně zobrazují jako závislosti reflektance na vlnové délce (viz kapitola 3.2, obrázek 9), ale při jejich vzájemném porovnávání nebo při extrakci informace o konkrétním zaznamenaném spektru není toto 2D zobrazení dostatečné. Za účelem využití maximálního množství informace obsažené v zaznamenaném spektru se využívá reprezentace dat v nově definovaném spektrálním prostoru. [21]

Využívá se reprezentace dat v N-dimenzionálním spektrálním prostoru, kde N představuje počet spektrálních pásem. Spektrum konkrétního materiálu odpovídá pozici bodu v takovémto spektrálním prostoru, resp. odpovídá konkrétnímu spektrálnímu vektoru. Na obrázku 30 vlevo je zobrazená jednoduchá ukázka spektrálního vektoru ve 2 dimenzionálním spektrálním prostoru. Vektory se stejnou orientací, ale s rozdílnou velikostí odpovídají spektru stejného materiálu, pouze s rozdílným jasem daných pixelů. [21]


Tímto způsobem lze vytvořit hyperdimenzionální spektrální prostor definovaný desítkami až stovkami vzájemně na sebe kolmých os. Podobnosti mezi spektry se vyhodnocují na základě blízkosti jednotlivých bodů ve spektrálním prostoru (jejich spektrální vzdálenosti) nebo podle velikosti úhlů mezi spektrálními vektory. [21]



Obr. 30, vlevo - Ukázka zobrazení konkrétního spektrálního vektoru v N-dimenzionálním spektrálním prostoru, pro nejjednodušší příklad ($N = 2$) [21]
vpravo - Znázornění spekter odpovídajících 3 materiálům a jejich vzájemná spektrální vzdálenost (pro $N=2$) [21]


5.3 Spektrální míchání (spectral mixing)

V ideálním případě hyperspektrálního snímání by zaznamenaná spektra na každém pixelu přesně odpovídala spektrální charakteristice konkrétního materiálu, dle jeho umístění na snímané scéně. Avšak kvůli malému prostorovému rozlišení spektrální kamery a vlivu rozptýlů záření dochází k tzv. spektrálnímu míchání. [50]



Obr. 31 - Ukázka spektrálního míchání v jednom pixelu [57]

V důsledku spektrálního míchání dopadá na buňku jediného pixelu více záření se spektrální charakteristikou pro konkrétní materiál, proto z výsledného spektrálního vektoru daného pixelu není možné přímo určit, jakému materiálu (nebo kombinaci materiálů) náleží. [57] Pixely přesně odpovídající konkrétnímu materiálu nazýváme čistými pixely (pure pixel), naopak pixely, u kterých není jednoznačně identifikovatelná spektrální charakteristika se nazývají pixely se smíchaným spektrem (mixed pixel). [58]



Obr. 32 - Význam Pure a mixed pixelu v hyperspektrálním zobrazování [58]


Ke vzniku spektrálního míchání může dojít třemi způsoby. [50] První způsob je způsobený malým prostorovým rozlišením spektrální kamery. V důsledku malého rozlišení pokrývá každý pixel větší plochu snímané scény. Na této ploše odpovídající jedinému pixelu se může nacházet více odlišných materiálů. Odražená záření od jednotlivých materiálů dopadají

na příslušný pixel, kde dochází k součtu jejich odražené energie, respektive k lineárnímu spektrálnímu míchání (obr. 33 a). [21] [50] Lineární míchání lze popsat následující rovnicí [50].

$$\mathbf{y} = \sum_{i=1}^p \alpha_i \mathbf{m}_i \quad (4)$$

Kde \mathbf{y} odpovídá vektoru změřených hodnot radiance v daném pixelu $\mathbf{y} = [y_1, \dots, y_N]$ pro N spektrálních pásem. Index i ($i = 1, \dots, p$) představuje index pro jednotlivé materiály. p je celkový počet obsažených materiálů. Vektor \mathbf{m}_i je tzv. spektrální znak pro i -tý materiál (endmember) a hodnota α_i vyjadřuje procentuální zastoupení i -tého materiálu v daném pixelu (abundance). [50]

Zbylé dva způsoby mají nelineární charakter. Příčinami jsou vícenásobné rozptyly záření v různých vrstvách atmosféry (obr. 33 b) a také odrazy od částicových směsí materiálů (obr. 33 c), [50] jako jsou například mikroskopické částice minerálů obsažené v půdě. [21]

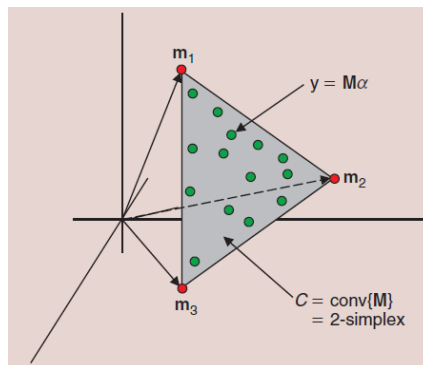


Obr. 33 - Tři možnosti vzniku spektrálního míchání [50]

Vliv spektrálního míchání na reprezentaci dat ve spektrálním prostoru je znázorněn na obrázku 34. Červené body označují vektory čistého spektra daného materiálu (pure spectral vectors = endmembers). Tyto body označují orientaci spektrálního vektoru pro daný materiál bez vlivu spektrálního míchání. Naopak zelené body značí spektrální vektory jejichž orientace byla změněna v důsledku spektrálního míchání (non-pure spectral vectors). [50]

V závislosti na struktuře povrchu snímané scény a vlivu spektrálního míchání se v zaznamenaném spektrálním prostoru mohou, ale i nemusí nacházet endmembers. Obalová plocha všech zaznamenaných bodů (konvexní obal) ve spektrálním prostoru představuje oblast

vlivu spektrálního míchání (mixing space), endmembers tvoří vrcholy této obalové plochy. [21] [50]



Obr. 34 - Vliv spektrálního míchání na reprezentaci dat ve spektrálním prostoru [50]

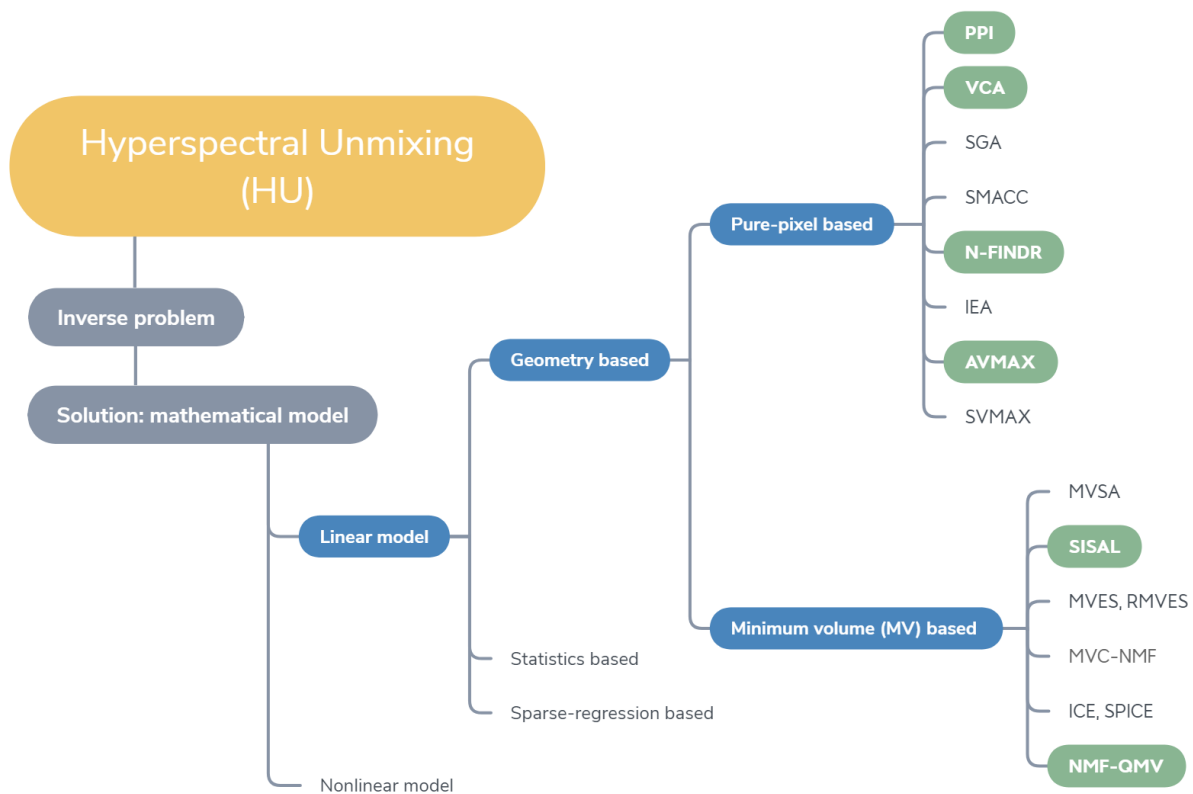
V důsledku spektrálního míchání není možné přímo z orientace spektrálních vektorů určit jaké materiály náleží jednotlivým pixelům. [50] Z toho důvodu je nutné použít metodu analýzy hyperspektrálních dat zvanou hyperspektrální rozklad.

5.4 Hyperspektrální rozklad (Hyperspektral Unmixing = HU)

HU představuje metodu analýzy hyperspektrálních dat, jejímž úkolem je identifikace všech hlavních materiálů (endmembers) obsažených ve snímané scéně a jejich následné využití k rozkladu spektra jednotlivých pixelů za účelem určení, jaké materiály (endmembers) a v jakém poměru (abundance) daný pixel obsahuje. [21]

Hyperspektrální rozklad je inverzní problém (případně problém separace zdrojů [60]), kdy známe výsledný efekt (změřený spektrální vektor daného pixelu) a hledáme příčiny (spektrální míchání) způsobující zkreslení vstupních veličin (spektrální znaky materiálů obsažených ve snímané scéně a jejich procentuální zastoupení). Řešení inverzního problému umožňuje určení hodnoty vstupních veličin, přestože nemůžou být přímo změřené. [50] Toho je dosaženo vytvořením matematického modelu, který odpovídá spektrálnímu míchání konečného množství materiálů obsažených ve snímané scéně. [45]

V současné době není stanovený žádný standard pro modely hyperspektrálního rozkladu. [45] Vytvoření algoritmů umožňujících co nejuvěrnější model spektrálního míchání je stále oblastí aktivního výzkumu. Obecně lze tyto algoritmy rozdělit na 2 hlavní skupiny, a to podle toho, zda je vytvořený model lineární či nelineární.



Obr. 35 - Dělení metod hyperspektrálního rozkladu

Volba použití lineárního či nelineárního modelování závisí na konkrétní aplikaci, na vlastnostech snímané scény a také na míře vlivu nelineárního míchání.

V nelineární variantě je modelován RTT (Radiative Transfer Theory) matematický model, který popisuje přesun energie při interakci fotonů s materiály obsaženými ve scéně. [61] Model popisující nelineární spektrální míchání poskytuje komplexní informace, avšak jeho vytvoření je velice náročný proces, který vyžaduje popsání velikého množství parametrů a jejich vzájemných vztahů. [45] Oproti tomu lineární model lze jednodušeji implementovat a poskytuje dostatečnou aproximaci popisu spektrálního míchání pro mnohé aplikace. [58] Navíc lineární model lze interpretovat jako problém slepé separace zdrojů (Blind Source Separation = BSS), který byl zkoumán již v několika oblastech signálového zpracování. [50] Proto se převládající část výzkumu v oblasti hyperspektrálního rozkladu věnuje metodám tvořících lineární modely spektrálního míchání. [45]


Na obrázku 35 je znázorněný přehled algoritmů pro řešení hyperspektrálního rozkladu. Modrou barvou jsou zvýrazněné metody, jejichž princip je popsán v této práci a zelenou barvou jsou vyznačené algoritmy jejichž účinnost byla porovnávána.

5.4.1 Linear Mixing Model (LMM)

Lineární model spektrálního míchání (LMM) předpokládá, že změřené hodnoty každého pixelu mohou být vyjádřeny jako lineární kombinace materiálů váhovaných jejich procentuálním rozložením. [45] Maticový zápis této lineární kombinace je:

$$Y = M\alpha \quad (5)$$

Kde matice $Y = [y_1, \dots, y_x]$ značí matici zaznamenaných dat. Ve sloupcích této matice je x (x = počet pixelů) změřených spektrálních vektorů o délce N (N = počet spektrálních pásem). Matice $M = [m_1, \dots, m_p]$ se nazývá maticí spektrálního míchání (mixing matrix) a skládá se z p (p = počet endmembers) spektrálních znaků o délce N . Posledním prvkem je matice procentuálního zastoupení jednotlivých materiálů (abundance matrix) $\alpha = [\alpha_1, \dots, \alpha_x]$, která má x sloupců a p řádků. [59]



Obr. 36 - Grafické znázornění základní rovnice modelu lineárního spektrálního míchání (ukázkový případ bez šumu)

Rovnice 5 znázorňuje ilustrativní případ modelu spektrálního míchání vyjádřeného v bezšumovém prostředí. V praxi je nutné počítat ještě se šumovou maticí N . [45]

$$Y = M\alpha + N \quad (6)$$

Při záznamu hyperspektrálních dat dochází ke zkreslení v důsledku různých zdrojů rušení. Ačkoliv jsou na získaná data aplikované různé korekce (viz preprocessing), tak je obtížné přesně odhadnout počet a typ šumů pro konkrétní měření. Pro modelování šumu se obvykle využívá IID (Independent and identically distributed) Gaussovský šum. [45]

Pro zajištění přesného řešení lineárního modelu jsou zavedena jistá omezení. Důležitým předpokladem je, že se snímaná scéna skládá z malého množství materiálů. [21] Každý z těchto materiálů je popsán svým spektrálním znakem ve sloupcích matice spektrálního míchání. Podmínkou je, že tyto spektrální znaky musí být lineárně nezávislé. [45]

Metody spektrálního rozkladu modelují spektra zaznamenaná v každém pixelu jako sumu dílčího zastoupení obsažených materiálů. [21] Při hledání správné kombinace zastoupení materiálů pro odpovídající pixel jsou pro usnadnění nalezení správného řešení uvažována dvě omezení. Prvním omezením je podmínka nezápornosti vektorů procentuálního zastoupení materiálů (Abundance Nonnegativity Constraint = ANC). Druhá podmínka vyjadřuje, že suma abundances různých materiálů musí být v každém pixelu rovna jedné (Abundance Sum to one Constraint = ASC). [45] [61]

Podmínka nezápornosti pro vektory abundance matrix (ANC):

$$\alpha_i \geq 0, \quad i = 1, \dots, x \quad (7)$$

Podmínka „sumy do jedné“ pro abundances daného pixelu (ASC):


$$\sum_{i=1}^x \alpha_i = 1 \quad (8)$$

Nutno dodat, že definice hlavních materiálů může být subjektivní a závislá na specifickém problému (například při potřebě rozlišení rostlin a půdy, stačí pro „zeleň“ jediný spektrální znak, avšak při jiné aplikaci by bylo například zapotřebí rozlišit užitečnou rostlinu od plevele, a tím pádem by již bylo zapotřebí větší množství spektrálních znaků pro jejich rozlišení). [61]

Z toho plyne, že pro některé aplikace mohou být zanedbávány spektrální znaky materiálů s malou četností ve scéně. V těchto případech lze očekávat, že hodnota sumy vektorů abundances bude menší než jedna. Řešením této situace je buď zrušení podmínky ASC, nebo její ponechání s tím, že způsobí nepřesnost ve výsledném modelu. [61]

5.4.1.1 Řetězec hyperspektrálního rozkladu (hyperspectral unmixing chain)

Hyperspektrální rozklad se tradičně řeší postupně v několika na sebe navazujících krocích. Nejprve je zaznamenaná radiance převedena na odpovídající reflektanci (viz preprocessing).



Obr. 37 - Řetězec hyperspektrálního rozkladu [45]

Dalším krokem je redukce dimenzionality spektrálního prostoru. Spektrální vektory, vzhledem k jemnému spektrálnímu rozlišení hyperspektrální kamery, mají často vysoce korelovaná data. [50] Vzhledem k tomu, že počet endmembers je obecně mnohem menší než počet spektrálních pásem N , tak lze předpokládat, že data spektrálních vektorů budou náležet nízko-dimenzionálnímu podprostoru. Proto lze použít metody redukce dimenzionality spektrálního prostoru (identifikace daného nízko-dimenzionálního podprostoru) jako jsou například metody PCA (Principal Component Analysis) nebo MNF (Minimum Noise Fraction). Snížení dimenze urychluje výpočetní čas unmixingu, redukuje množství dat a zvyšuje odstup signálu od šumu. [61] [21] Tento krok lze také označit jako výběr řádu modelu. [45]


Následuje nalezení počtu materiálů obsažených ve snímané scéně (p = počet endmembers), který by měl odpovídat počtu vrcholů konvexního obalu daného nízko-dimenzionálního podprostoru. [21] Při správném LMM modelování by dimenze tohoto podprostoru měla být rovna hodnotě o jedna menší, než je počet endmembers ($p - 1$). [61]

Nyní se z definovaného spektrálního podprostoru identifikují spektrální znaky pro jednotlivé materiály a vytvoří se matice spektrálního míchání \mathbf{M} . V posledním kroku se na

základě matice \mathbf{M} určí na každém pixelu rozložení jednotlivých materiálů ze snímané scény, tzn. určí se matice α (abundance matrix). [45]

5.5 Metody odhadu hlavních složek (endmembers estimation)

Jelikož lze lineární rozklad interpretovat jako problém separace zdrojů, tak pro řešení úlohy nalezení spektrálních znaků pro jednotlivé endmembers připadá v úvahu metoda ICA (Independent Component Analysis). Avšak tato metoda je založena na předpokladu, že zdrojové signály jsou vzájemně nezávislé, což není případ hyperspektrálního rozkladu, kde podmínka „sumy do jedné“ (ASC) naznačuje statistickou závislost. Z toho důvodu tato metoda není vhodná pro hyperspektrální rozklad. [50] [60] Při výzkumu algoritmů pro odhad hlavních složek se nejčastěji využívá geometrických nebo statistických charakteristik hyperspektrálních dat. [60]



Obr. 38 - Ilustrace odhadu tvaru konvexního obalu a spektrálních znaků endmembers (m_1 , m_2 , m_3) za využití metod: a) geometry - pure pixel based, b) geometry - minimum volume based, c) statistical [50]

Odvození hodnot matice spektrálního míchání \mathbf{M} je ekvivalentní k identifikaci vrcholů konvexního obalu. Mnoho algoritmů odhadu endmembers využívá tohoto geometrického popisu a jejich princip vychází z konvexní geometrie (konvexní obal N -dimenzionálního prostoru je definovaný jako lineární kombinace vybraných bodů, které následně tvoří vrcholy tohoto obalu. Použité váhy jsou kladné a jejich součet je roven jedné, což přesně odpovídá definici lineárního modelu spektrálního míchání). [61] [62] Geometrické metody dělíme na dvě skupiny, podle toho zda uvažované modely předpokládají přítomnost čistých pixelů (pure pixel based algorithms) či nikoliv (non-pure pixel based algorithms). [50]

U první jmenované skupiny (obr. 38 a) je pro každý materiál předpokládána přítomnost alespoň jednoho pixelu, který náleží čistě danému materiálu (pure pixel). Tedy, že mezi zaznamenanými daty se nachází alespoň jeden spektrální vektor pro všechny vrcholy

konvexního obalu. V případě non-pure pixel based algoritmů se nepočítá s čistými pixely mezi zaznamenanými daty, ale je zde požadavek na alespoň $p - 1$ spektrálních vektorů u každé hrany konvexního obalu (obr. 38 b). Metody z této skupiny se zaměřují na nalezení minimálního objemu konvexního obalu [Minimum Volume (MV) simplex] tak, aby jeho součástí byly ještě zaznamenané spektrální vektory. [61] Na zbývajícím obrázku (obr. 38 c) je vyobrazena situace, kdy jsou na vstupu data s velkým vlivem spektrálního míchání, jejichž spektrální vektory se nenachází ani v blízkosti hran. Pro tuto variantu již není vhodná žádná geometricky založená metoda, využívá se statistického přístupu. [50]

5.5.1 Statistické metody

Statistické metody odhadu endmembers jsou mocnou alternativou pro metody geometrické, které neposkytují dostatečné výsledky v případě velkého vlivu spektrálního míchání. Statistické metody vychází z Bayesovské analýzy a umožňují unmixing i pro vysoce „smíchaná“ data za cenu vyšší výpočetní náročnosti. [60]

Metody uplatňující Bayesovský přístup jsou založeny na určení pravděpodobnosti požadovaných parametrů (mixing matrix \mathbf{M} & abundance matrix α) na základě výpočtu z lineárního modelu a apriorní pravděpodobnosti určené tak, aby splňovala daná omezení. Dosažení tohoto postupu může být například využitím metody Markov Chain Monte Carlo (MCMC). [50]

5.5.2 Metoda řídké regrese (sparse regression = SR)

Kromě geometrických a statistických metod lze pro odhad endmembers využít ještě metodu řídké regrese. Tato metoda funguje na odlišném principu, kde zaznamenaná data jsou porovnávána se spektrální knihovnou.

SR formulace vyjadřuje změřené spektrální vektory jako lineární kombinaci malého množství známých spektrálních znaků, vybraných ze spektrální knihovny. Úkolem této metody je nalezení optimální kombinace materiálů obsažených ve spektrální knihovně tak, aby bylo možné co nejlépe modelovat každý pixel obsažený ve snímané scéně. Jedná se o problém kombinatoriky. [50] [61]

Přesnost lineárních SR závisí na využití vhodné knihovny. Spektrální knihovny obsahují velké množství spektrálních znaků, jejichž pořízení je časově náročná a obecně drahá procedura. Je také nutné brát v potaz, že spektrální znaky z knihovny a zaznamenaná data ze

sledované scény budou pravděpodobně pořízené za odlišných podmínek, z toho důvodu je nutné počítat s důkladnou kalibrací dat. Možností jak tento proces usnadnit je zavedení nového přístupu, kde je využito algoritmu „učení se“ (dictionary learning) spektrálních znaků přímo z datasetů pořízených danou hyperspektrální kamerou. [61]

5.5.3 Geometrické metody - pure pixel based

Tato skupina metod odhadu endmembers, jak již plyne z jejího názvu, je založena na předpokladu, že součástí změřených dat je alespoň jeden čistý pixel pro každý materiál obsažený ve snímané scéně. Z geometrického hlediska tato definice odpovídá tomu, že známe vrcholy uvažovaného konvexního obalu (každému vrcholu odpovídá alespoň jeden spektrální vektor). [50] [61]

Předpoklad přítomnosti čistých pixelů v zaznamenané scéně umožňuje sestavení výpočetně nenáročných a účinných algoritmů, které však nelze uplatnit pro všechny případy hyperspektrální analýzy. [50] [61]

Většina algoritmů z této skupiny vychází buď z předpokladu, že extrémy projekce spektrálních vektorů ve spektrálním prostoru odpovídají endmembers nebo, že objem konvexního obalu je největší je-li složen právě z endmembers (objem konvexního obalu složený z kombinace jiných spektrálních vektorů je dle této definice menší). [50]

Do první jmenované kategorie (extrémy projekce) patří tyto algoritmy:

Pixel Purity Index (PPI)*

Vertex Component Analysis (VCA)*

Simplex Growing Algorithm (SGA)

Successive Volume MAXimization (SVMAX)

Druhou skupinu (objem konvexního obalu) tvoří:

N-FINDR*

Iterative Error Analysis (IEA)

Sequential Maximum Angle Convex Cone (SMACC)

Alternating Volume MAXimization (AVMAX)*

V rámci této práce jsou testovány algoritmy označené *

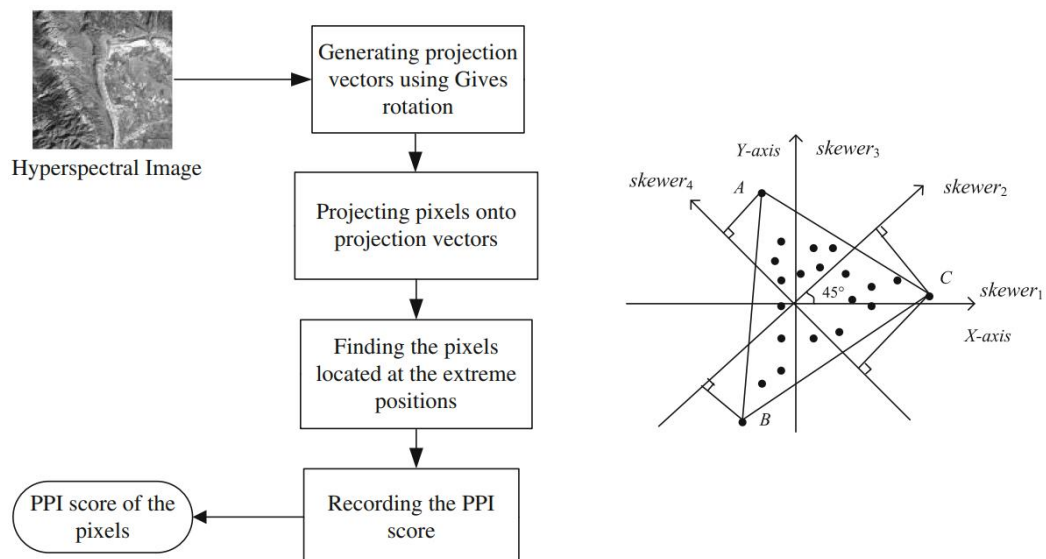
Na vstupu algoritmů je testovaný HSI snímek již s redukovanou dimenzí a odhadovaný počet endmembers p . S HSI snímkem lze pracovat jako s maticí formátu (Nr, x) , kde Nr je redukovaný počet spektrálních pásem a x je počet všech pixelů. Jednotlivé sloupce této matice odpovídají spektrálním vektorům pro každý pixel HSI snímku (x spektrálních vektorů).

Výstupem jednotlivých algoritmů je odhadovaná matice míchání formátu (Nr, p) .

5.5.3.1 Pure Pixel index (PPI)

Algoritmus PPI je založen na generování náhodných vektorů o délce N (tzv. skewers). Na vstupu tohoto algoritmu se definuje jejich počet $num_skewers$ [63], který ovlivňuje přesnost algoritmu, ale také i výpočetní náročnost (čím více vektorů, tím by měl být algoritmus přesnější na úkor výpočetní rychlosti). Všechny spektrální vektory testovaného HSI snímku se promítnou na jednotlivé skewers a následně se vyhodnocují extrémy jednotlivých projekcí. Pro každou projekci spektrálních vektorů na skewers se v pomocném vektoru („zásobníku“) přičítá hodnota jedna na pozici odpovídající pixelu s extrémem. Po dokončení cyklu všech projekcí jsou pixely s největším počtem extrémů označeny za pixely „nejčistší“ (purest ones). Spektrální vektory z p „nejčistších“ pixelů se uloží do výstupní matice míchání. [61] [65]


V případě rozšířené varianty algoritmu PPI se v prvním kroku místo náhodných vektorů definují vektory s konkrétním úhlem natočení. [65]



Obr. 39 - Schématické a grafické znázornění algoritmu PPI (rozšířená varianta s definováním úhlů natočení jednotlivých skewers) [65]

5.5.3.2 Vertex Component Analysis (VCA)

Algoritmus VCA vyhledává extrémy p vzájemně ortogonálních projekcí HSI snímku. [61] jeho princip je znázorněn na obrázku níže.



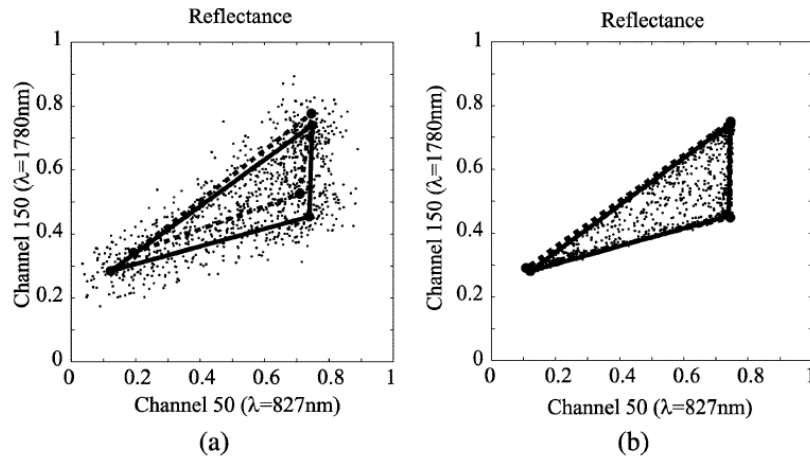
Obr. 40 - Ilustrace principu algoritmu VCA [64]

Spektrální vektory HSI snímku leží v podprostoru E_p o dimenzi p . V prvním kroku se provede jejich projekce ($\mathbf{X} = \mathbf{U}d \times \text{HSI}$) na simplex S_p ležící v prostoru o dimenzi $p - 1$. Podle hodnoty odstupe signálu od šumu se matice projekce $\mathbf{U}d$ generuje na základě metody SVD (Singular Value Decomposition) nebo PCA (Principal Component Analysis). Důležitou podmínkou je, aby vektor projekce u svíral s vektory originálního snímku vzájemně úhel ležící v intervalu 0 až 45° , čímž se zamezí chybám výpočtu pro úhly blízké 90° . Po ošetření těchto podmínek vzniká matice \mathbf{Y} , převod HSI snímku na tuto matici umožňuje snížení vlivu šumu. Význam použití jmenovaných projekcí je znázorněn na obrázku 41. [64] [61]

V druhém kroku se vytvoří pomocná matice $\mathbf{A} = [e_1, e_2 \dots e_p]$, do jejíž sloupců se budou později iterativně ukládat projekce spektrálních znaků. Na začátku je matice \mathbf{A} nulová s výjimkou prvního sloupce $e_1 = [0, 0 \dots 0, 1]$. [64] [61]

Následuje samotný algoritmus VCA, který proběhne v p iteracích. Při každém opakování se vygeneruje náhodný vektor f ortonormální k prostoru tvořeném sloupci matice \mathbf{A} . HSI snímek upravený podle prvního kroku (matice \mathbf{Y}) se následně promítne na vektor f , čímž vznikne vektor v ($v = (f)' \times \mathbf{Y}$). Spektrální znak endmemberu odpovídá maximu tohoto vektoru

a uloží se do p -týho sloupce matice \mathbf{A} , zároveň se uloží index tohoto pixelu i . Po provedení všech iterací budou sloupce matice \mathbf{A} odpovídat jednotlivým spektrálním znakům. V posledním kroku se vypočítají sloupce matice míchání \mathbf{M} , jako $\mathbf{M} = \mathbf{Ud} \times \mathbf{Xi}$, kde i odpovídá indexům pixelů s nalezenými maximy. [64] [61]



Obr. 41 - Bodový graf (pro $\lambda_1 = 827\text{nm}$ a $\lambda_2 = 1780\text{nm}$) znázorňující HSI snímek tvořený třemi materiály, plnou čarou jsou propojené skutečné polohy endmembers, přerušované je znázorněný odhad VCA. a) data bez projekce, b) data promítnutá pomocí SVD. [64]

5.5.3.3 N-FINDR

Základní myšlenkou algoritmu N-FINDR je nalezení pixelů daného HSI snímku, jejichž kombinací lze sestavit konvexní obal s maximálním objemem. Tento algoritmus vychází z předpokladu, že jakoukoli kombinací jiných, než „nejčistších“ pixelů, nelze sestavit větší konvexní obal. Spektrální vektory z „nejčistších“ pixelů budou označeny jako endmembers. [61] [66]

Předchozí jmenované algoritmy pracují v sekvenčním módu, tedy v rámci těchto algoritmů jsou endmembers určovány postupně v jednotlivých iteracích. V algoritmu N-FINDR se endmembers určují paralelně. Je hledána správná kombinace spektrálních vektorů, a tudíž jsou všechny endmembers určovány zároveň. [66]

Na vstupní data je nejprve aplikována redukce dimenzionality za účelem snížení dimenze na $p - 1$. K tomu se využívá buď metoda PCA (Principal Component Analysis) nebo MNF (Minimum Noise Fraction). [67]

V dalším kroku se ze vstupního snímku sestaví set náhodně vybraných spektrálních vektorů $\mathbf{E} = [e_1, \dots, e_p]$. Následuje hledání takové kombinace spektrálních vektorů, aby bylo

dosaženo maximálního objemu konvexního obalu. Objem konvexního obalu dané matice \mathbf{E} se počítá podle vzorce (9). [66] [67]

$$V(\mathbf{E}) = \frac{|\det(\mathbf{E})|}{(p-1)!} \quad (9)$$

Nyní se opakuje cyklus pro hledání největšího objemu. Tento cyklus se opakuje postupně pro všechny spektrální vektory z každého pixelu vstupního snímku. Po výběru spektrálního vektoru následuje vnitřní cyklus, ve kterém se postupně nahrazují jednotlivé sloupce matice \mathbf{E} daným vektorem a pro každou pozici tohoto vektoru se počítá objem V . Pokud žádný ze spočítaných objemů není větší než objem úvodní matice \mathbf{E} , tak tato matice zůstává v původní podobě. V opačném případě dostává matice \mathbf{E} takovou podobu, ve které byl spočítán největší objem. [61] [66] [67]

Názorný příklad: pro první 4 pixely nebyl vypočítán větší objem, a tak zůstává matice \mathbf{E} beze změny, ale pro pátý pixel byl vypočítán větší objem při druhé iteraci, proto se mění aktuální podoba matice na $\mathbf{E} = [e_1, x(5), e_3, \dots, e_p]$, kde $x(5)$ značí spektrální vektor z pátého pixelu.

Algoritmus se ukončuje po otestování všech pixelů. Výstup algoritmu, matice míchání \mathbf{M} , odpovídá výsledné matici \mathbf{E} . [61]

5.5.3.4 Alternating Volume MAXimization (AVMAX)


N-FINDR je jeden ze základních algoritmů geometrických metod hyperspektrálního rozkladu. V současné době existuje několik algoritmů, které vycházejí ze stejného principu. Tyto algoritmy vycházející z N-FINDERu jsou založené na odlišném přístupu k vyhledávání pixelů, jiné struktuře algoritmu nebo výpočetních metodách. Například jde o algoritmy Iterative N-FINDR (I-N-FINDR), Sequential N-FINDR (SQ-N-FINDR), Simplex Growing Algorithm (SGA). Mezi tyto algoritmy patří i AVMAX. [68]

Algoritmus AVMAX představuje alternující optimalizaci algoritmu N-FINDR. Základní struktura algoritmu je obdobná jako u N-FINDERu. Algoritmy se odlišují uvnitř opakujícího se cyklu pro hledání maximálního objemu. V rámci tohoto cyklu probíhá výpočet maximálního objemu vzhledem k jedinému zafixovanému spektrálnímu vektoru, zatímco ostatní iterují. V pomocném vektoru se ukládají indexy vektorů s maximálním objemem, které budou následně tvořit matici \mathbf{M} . [61] [68]

5.5.4 Geometrické metody - Minimum Volume (MV) based

MV algoritmy hledají takové hodnoty matice spektrálního míchání \mathbf{M} , aby bylo dosaženo minimálního objemu konvexního obalu pokrývajícího změřené spektrální vektory. Tyto metody již nemají podmínku přítomnosti čistých pixelů (jedná se o non-pure pixel based algorithms), proto je jejich řešení mnohem složitější nekonvexní optimalizační problém. Nezbytnou podmínkou je však požadavek na $p - 1$ spektrálních vektorů v blízkosti všech hran konvexního obalu. [50] [61]

Základní krok těchto algoritmů je postupná změna hran uvažovaného konvexního obalu (zatímco se mění umístění jedné hrany, tak jsou ostatní hrany zafixované, atd.) dokud není dosaženo minimálního objemu konvexního obalu tak, aby jeho součástí byly stále všechny zaznamenané spektrální vektory (stále platí omezení ANC a ASC). [61] Tento krok se nazývá regularizace objemu [volume regularizer = $V(\mathbf{M})$] a umožňuje přiblížení tvaru skutečného konvexního obalu (viz obr. 42 vlevo). [50]



Obr. 42, vlevo - znázornění minimálního konvexního obalu získaného regulací objemu $V(M)$
vpravo - vliv šumu způsobující nepřesné změření spektrálních vektorů a tím ovlivňující odhad konvexního obalu [61]

Avšak při vyhodnocování reálných snímků jsou data zatížena šumem, a proto může docházet k situaci, kde změřené spektrální vektory leží mimo skutečný konvexní obal. Aplikace pouze regularizace objemu uvedené výše by vedlo k výraznému zkreslení odhadu (viz obr 42 vpravo). Z toho důvodu je nutné MV algoritmy patřičně modifikovat, aby byl umožněn co nejpřesnější odhad endmembers. [61]

Problém optimalizace MV based HU algoritmů lze formulovat jako:

$$\begin{aligned} & \min_{\mathbf{M}, \boldsymbol{\alpha}} \frac{1}{2} \|\mathbf{Y} - \mathbf{M}\boldsymbol{\alpha}\|_F^2 + \beta V(\mathbf{M}) \\ & \text{pro: } \boldsymbol{\alpha} \geq 0, \sum_{i=1}^x \alpha_i = \mathbf{1} \text{ (ANC a ASC)} \end{aligned} \quad (10)$$

Kde $\|\cdot\|_F$ je Frobeniova norma. Celá funkce se skládá ze dvou částí, které minimalizuje. První část, $\frac{1}{2} \|\mathbf{Y} - \mathbf{M}\boldsymbol{\alpha}\|_F^2$, odpovídá vzdálenosti mezi originálním a rekonstruovaným snímkem, tzn. v první části je sledována chyba aproximace. Druhá část, $V(\mathbf{M})$, měří objem konvexního obalu matice spektrálního míchání \mathbf{M} . β je regularizační parametr, který zajišťuje kompromis mezi oběma částmi funkce (aproximační chyba a objem konvexního obalu). [59] [61]

Na základě formulace vyjádřené vzorcem (10) funguje většina MV metod, jejich vzájemné rozdíly se převážně liší ve formulaci jednotlivých částí vzorce. Z níže jmenovaných MV metod tomuto vzorci odpovídají algoritmy MVC-NMF, ICE a jeho novější modifikace SPICE [tyto metody se vzájemně liší definicí regularizéru $V(\mathbf{M})$]. [50]

MVSA, SISAL a RMVES, obdobně jako výše zmíněné algoritmy, se skládají ze dvou částí (sledující aproximační chybu, objem konvexního obalu) a regularizátoru zajišťujícího kompromis mezi nimi. Největší rozdíl těchto algoritmů oproti algoritmům jmenovaným v předchozí části je, že je u nich možnost porušit podmínku ANC, což zajišťuje větší robustnost. [61]

MV based algoritmy:

Iterative Constrained Endmembers (ICE)

Sparsity-Promoting Iterative Constrained Endmembers (SPICE)

Minimum Volume transform - Nonnegative Matrix Factorization (MVC-NMF)

Nonnegative Matrix Factorization Quadratic Minimum Volume (NMF-QMV)*

Minimum Volume Simplex Analysis (MVSA)

Robust Minimum Volume Enclosing Simplex (RMVES)

Simplex Identification via variable Splitting and Augmented Lagrangian (SISAL)*


V rámci této práce jsou testovány algoritmy označené *

5.5.4.1 SISAL

Algoritmus SISAL, celým názvem Simplex Identification via variable Splitting and Augmented Lagrangian, se řadí do geometrických metod hyperspektrálního rozkladu založených na principu MV.

U tohoto algoritmu je podmínka nezápornosti (ANC), tzv. tvrdé omezení (hard constrain), nahrazena měkkým omezením (soft constrain). Zatímco u výše popsaných algoritmů nebyly tolerované záporné hodnoty, tak u algoritmu SISAL jsou záporné hodnoty penalizovány v závislosti na jejich velikosti, použitím tzv. hinge function. Tato úprava omezení činí algoritmus SISAL odolný vůči šumu a spektrálním vektorům ležící mimo konvexní obal (outliers). [61] [69]

Vstupní HSI snímek je nejprve promítnutý na podprostor o dimenzi $p-1$. Následuje inicializace pomocí pure pixel algoritmu VCA. Odhadovaná matice míchání \mathbf{M}_{vca} (výstup algoritmu VCA) je zvětšená o matici $d\mathbf{Q}$, která odpovídá rozdílu každé buňky matice \mathbf{M} a průměrné hodnoty v odpovídajícím řádku, $\mathbf{M}(0) = \mathbf{M} + d\mathbf{Q}$. Takto vzniklá matice $\mathbf{M}(0)$ představuje objektivní funkci optimalizace. Následuje cyklus o k iteracích, během kterého je hledán minimální objem konvexního obalu daného HSI snímku, minimum $V[\mathbf{M}(0)]$. K řešení optimalizační úlohy algoritmus SISAL využívá variable splitting augmented Lagrangin algorithm. Průběh optimalizace je znázorněn na obrázku níže. [61] [69]



Obr. 43 - Ukázka minimalizace objektivní funkce v algoritmu SISAL [61]

5.5.4.2 NMF-QMV

Nonnegative Matrix Factorization Quadratic Minimum Volume (NMF-QMV) je ucelený framework vycházející z formulace hyperspektrálního rozkladu pomocí NMF. Tento algoritmus zahrnuje populární metody minimalizace objemu (MV) komplexního obalu matice spektrálního míchání \mathbf{M} . Autoři tohoto frameworku se primárně zaměřili na způsob, jakým lze vybalancovat chybu aproximace matice \mathbf{M} a odhad na základě minimalizace objemu konvexního obalu, tzn. zaměřili se na volbu regularizačního parametru β . Volba regularizačního parametru je náročný, ale důležitý bod hyperspektrálního rozkladu, který byl ve většině MV algoritmů nastavován manuálně v závislosti na vlastnostech testovaných datasetů. V rámci tohoto frameworku je regularizační parametr volen automaticky. [59]


Obdobně jako u předchozích algoritmů je vstupní snímek nejprve promítnutý na podprostor o dimenzi $p-1$. Následuje řešení nekonvexního optimalizačního problému, který je u NMF-QMV vyjádřený následovně:

$$\min_{\mathbf{M}, \boldsymbol{\alpha}} \frac{1}{2} \|\mathbf{Y} - \mathbf{M}\boldsymbol{\alpha}\|_F^2 + \frac{\beta}{2} \|\mathbf{A}\mathbf{B} - \mathbf{O}\|_F^2 \quad (11)$$

pro: $\boldsymbol{\alpha} \geq 0, \sum_{i=1}^x \alpha_i = \mathbf{1}$ (ANC a ASC)

Tzn. pro NMF-QMV platí podmínky ANC i ANS, popis chyby aproximace je obdobný jako ve vzorci (10) a popis MV vyjádřený druhou částí vzorce závisí na definici dvojice parametrů (\mathbf{B}, \mathbf{O}) . Balanc mezi oběma částmi funkce zajišťuje regularizační parametr β . [59]

NMF-QMV umožňuje jako vstupní parametr volbu jednoho ze tří kvadratických MV regularizátorů (Boundary, Center nebo Total Variance), které zajišťují jakým směrem se budou měnit odhady endmembers. Pro každou variantu jsou odlišně definované parametry (\mathbf{B}, \mathbf{O}) . Princip jednotlivých regularizátorů je znázorněn na obrázku 44 a jejich matematický popis v tabulce 1. [59]




Obr. 44 - Znázornění principu kvadratických MV regularizátorů [59]

Tabulka 2: Definice parametrů (B,O) použitých MV regularizátorů

MV terms	Definitions of (B, O)
boundary	$\mathbf{B} = \mathbf{I}_p$ $\mathbf{O} = \text{extremes given by VCA (or other methods)}$
center	$\mathbf{B} = \mathbf{I}_p$ $\mathbf{O} = \frac{1}{x} \mathbf{Y} \mathbf{1}_x \mathbf{1}_p^T$
TV	$\mathbf{B} = (\mathbf{I}_p - (1/p) \mathbf{1}_p \mathbf{1}_p^T)$ $\mathbf{O} = \mathbf{0}$

\mathbf{I}_p = jednotková matice velikosti p , \mathbf{Y} = originální HSI snímek,
 x = počet pixelů

První jmenovaný MV regularizátor, Boundary, směřuje odhad endmembers k extrémům určených pomocí VCA nebo jiného pure pixel algoritmu (je doporučeno, aby vybraný algoritmus byl odolný vůči „outliers“). Druhý regularizér, Center, směřuje odhad endmembers do středu dat. Zde může nastat problém při nerovnoměrném rozdělení dat. Poslední, Total Variance, MV regularizér směřuje odhad doprostřed mezi jednotlivými endmembers. [59]



Obr. 45 - Význam regularizačního parametru beta [59]

Pro správné vyhodnocení hyperspektrálního rozkladu je velice důležitá správná volba regularizačního parametru β . Význam tohoto parametru je znázorněn na obrázku 45. Pro příliš velkou hodnotu β je v optimalizační rovnici kladen důraz převážně na minimalizaci objemu konvexního obalu pouze s malým ohledem na chybu aproximace (zelený trojúhelník na obrázku 45). Naopak v případě nulové hodnoty regularizačního parametru není brán ohled na minimalizaci objemu a stanovený komplexní obal by obklopoval všechny spektrální vektory (červený trojúhelník na obrázku 45). V rámci NMF-QMV je hodnota regularizačního parametru volena na základě hledání minimální vzdálenosti mezi hraničními spektrálními vektory (boundary data points) a mezi okraji odhadovaného konvexního obalu pro různé

hodnoty regularizačního parametru. Pro správné řešení této optimalizační úlohy by měla být nalezena taková hodnota regularizačního parametru, pro kterou odhadovaný konvexní obal odpovídá tomu skutečnému (modrý trojúhelník na obrázku 45).

6 Databáze hyperspektrálních dat

Pro účely této práce byla sestavena databáze HSI dat¹. Databáze obsahuje volně dostupné snímky z hyperspektrálních kamer z oblasti vzdáleného snímání (remote sensing), testovací snímky z komerčně prodávaných HSI kamer a také synteticky vytvořené HSI snímky vhodné k testování vlastností jednotlivých algoritmů hyperspektrálního rozkladu.

6.1 Reálné HSI snímky

Součástí databáze je 34 hyperspektrálních snímků z reálných kamer. Jednotlivé snímky byly pořízeny různými systémy s odlišnými parametry (rozlišení, počet spektrálních pásem, spektrální rozsah, nadmořská výška snímání, aj. viz kapitola 4.4).

29 snímků spadá do kategorie remote sensing. Tyto snímky byly pořízeny buď hyperspektrální kamerou umístěnou na palubě letadla (airborne) nebo satelitu (spaceborne). Do kategorie leteckého vzdáleného snímání patří například snímky pořízené systémem AVIRIS (Airborne Visible/Infrared Imaging Spectrometer). HSI kamera z tohoto systému zaznamenává data ve 224 spektrálních pásmech v rozsahu 400–2500 nm. HSI data systému AVIRIS jsou zaznamenávána v nadmořské výšce 20km za přibližné rychlosti letu 730 km/h, případně 4km nad mořem v rychlosti 130 km/h při použití jiného typu letadla. [70] Příkladem satelitního snímání je systém EO-1 Hyperion. EO-1 (Earth Observing 1) je satelit společnosti NASA aktivní v letech 2000 až 2017 obíhající zemi v nadmořské výšce 700 km, Hyperion je označení hyperspektrálního systému, jenž byl součástí tohoto satelitu. Umožňoval zaznamenávat HSI snímky ve 220 spektrálních pásmech v rozsahu 400–2500 nm. Snímky z tohoto systému jsou archivovány institutem USGS (United States Geological Survey). [71]

Kromě dostupných HSI snímků z oblasti remote sensing existuje také nespočet online databází poskytujících různé testovací snímky pořízené komerčně prodávanými hyperspektrálními kamerami či experimentálními HSI projekty (Např. [72] [73] [74]) Do zmiňované databáze bylo vybráno 5 ukázkových snímků tohoto typu.

¹ Databáze je uložena na cloudovém úložišti a je možné ji otevřít prostřednictvím tohoto odkazu: <https://owncloud.cesnet.cz/index.php/s/BNTaXWtJdKfxw2y>

HSI snímky jsou k dispozici ke stažení v různých formátech (RAW, ENVI, MAT).

Základní možností jsou RAW formáty, tedy surová data přímo z kamery (formáty .raw nebo .tif). Častou možností je stažení hyperspektrálních snímků ve formátu označeném jako ENVI. ENVI (Environment for Visualizing Images) je software na analýzu snímků využívaný pracovníky a vědci v oblasti vzdáleného snímání nebo analýzy snímků (včetně hyperspektrální analýzy). Po nahrání a případném zpracování tímto programem jsou HSI snímky uloženy do tzv. ENVI formátu. Jedná se o dvojici souborů: hlavičkový soubor formátu .hdr obsahující metadata a binární soubor odpovídající samotnému snímku (formáty .bsq, .bip, .bil) případně jsou podporované i rastrové formáty .dat, .img, aj. [75] [76]

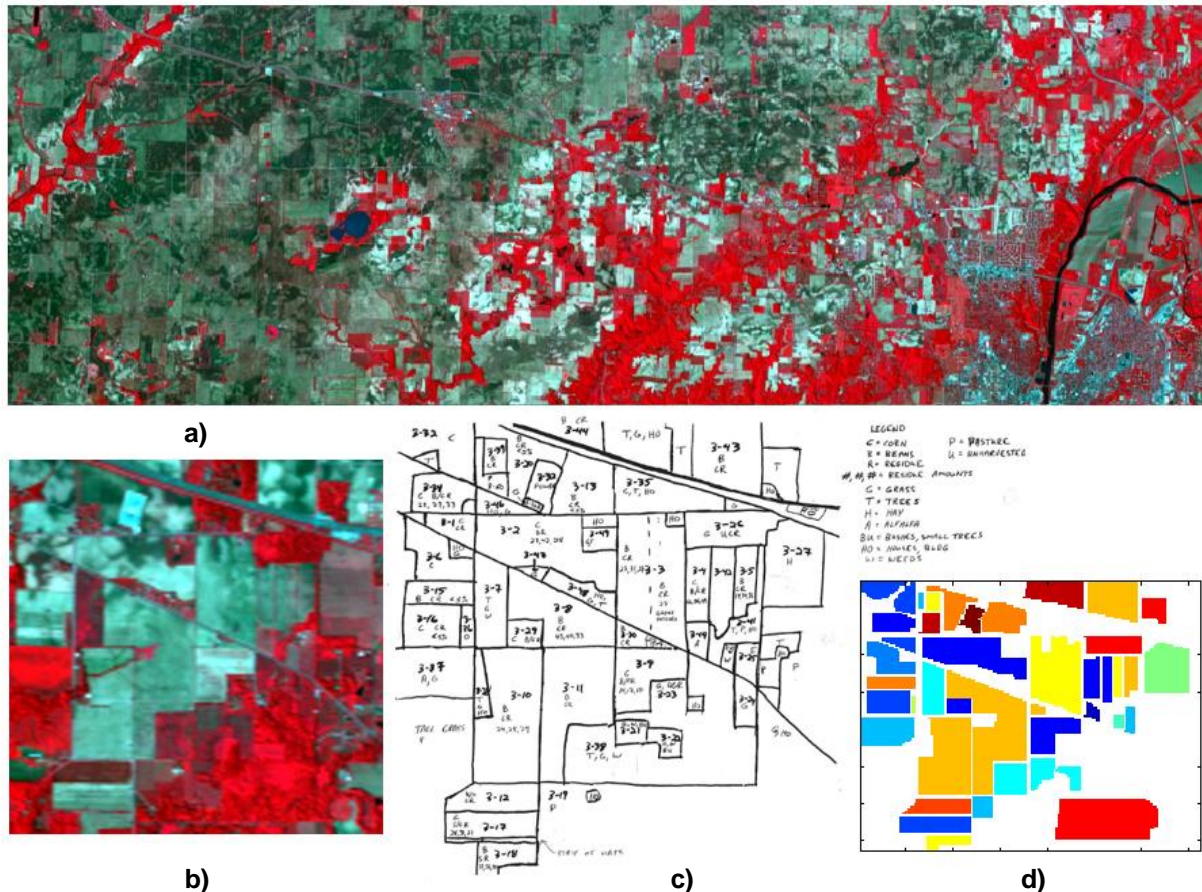
Další častou variantou jsou hyperspektrální snímky ve formátu .mat určeném pro programové prostředí softwaru MATLAB (MATrix LABoratory). Porovnání algoritmů hyperspektrálního rozkladu v rámci této diplomové práce byla provedena v tomto programu.

Tabulka 3: Seznam HSI snímků obsažených v databázi

SEZNAM VŠECH SNÍMKŮ												
LETECKÉ A SATELITNÍ HYPERSPECS SNÍMKY						OSTATNÍ HYPERSPECS SNÍMKY						
#	Zdroj	Název	MATLAB	ENVI	RAW	#	Zdroj	Název	MATLAB	ENVI	RAW	
1	11	Ankara	MAT	MAT_gt	HDR	1	A	Scene33 (outdoor photo)	MAT	MAT_wave	HDR	DAT
2	1	Botswana	MAT	MAT_gt	HDR	2	A	Scene71 (color chart)	MAT	MAT_wave	HDR	
3	1 3	Cuprite	MAT	MAT_gt	HDR	3	A	Pineapple	MAT	MAT_wave	HDR	
4	12 13	D1_F12_H1_Cropped	MAT	MAT_gt	HDR	4	C	Gualtar_Villa	MAT	MAT_wave		
5	6	Gulf of Mexico wetland	MAT	MAT_gt	HDR	5	D	nogueiro_1600	MAT	MAT_wave		
6	14	hypexp_murphy_dome_quarry_subset	MAT	MAT_gt	HDR	6			MAT	MAT_wave		
7	14	hypexp_yukon_flats_alaska_subset	MAT	MAT_gt	HDR	7			MAT	MAT_wave		
8	15	ChangeDetectionDataset - bayArea	MAT	MAT_gt	HDR	8			MAT	MAT_wave		
9	15	ChangeDetectionDataset - Hermiston	MAT	MAT_gt	HDR	9			MAT	MAT_wave		
10	15	ChangeDetectionDataset - santaBarbara	MAT	MAT_gt	HDR	10			MAT	MAT_wave		
11	10	Chikusei	MAT	MAT_gt	HDR	11			MAT	MAT_wave		
12	1 4	Indian Pines	MAT	MAT_gt	HDR	12			MAT	MAT_wave		
13	2 3	Jasper Ridge	MAT	MAT_gt	HDR	13			MAT	MAT_wave		
14	1	Kennedy Space Center	MAT	MAT_gt	HDR	14			MAT	MAT_wave		
15	9	Kootenai River	MAT	MAT_gt	HDR	15			MAT	MAT_wave		
16	7	Moffett Field	MAT	MAT_gt	HDR	16			MAT	MAT_wave		
17	1	Pavia Centre	MAT	MAT_gt	HDR	17			MAT	MAT_wave		
18	1	Pavia University	MAT	MAT_gt	HDR	18			MAT	MAT_wave		
19	1	Salinas	MAT	MAT_gt	HDR	19			MAT	MAT_wave		
20	1	Salinas-A	MAT	MAT_gt	HDR	20			MAT	MAT_wave		
21	2 3	Samson	MAT	MAT_gt	HDR	21			MAT	MAT_wave		
22	2	The China & USA dataset	MAT	MAT_gt	HDR	22			MAT	MAT_wave		
23	2 5	The Washington DC Mall	MAT	MAT_gt	HDR	23			MAT	MAT_wave		
24	2 3	Urban	MAT	MAT_gt	HDR	24			MAT	MAT_wave		
25	9	Snake River	MAT	MAT_gt	HDR	25			MAT	MAT_wave		
26	6	Beltsville (Agriculture & vegetation)	MAT	MAT_gt	HDR	26			MAT	MAT_wave		
27	6	Reno (urban sample)	MAT	MAT_gt	HDR	27			MAT	MAT_wave		
28	7	Lunar Lake	MAT	MAT_gt	HDR	28			MAT	MAT_wave		
29	7	Low Altitude	MAT	MAT_gt	HDR	29			MAT	MAT_wave		
30			MAT	MAT_gt	HDR	40			MAT	MAT_wave		

V tabulce 3 je seznam všech HSI snímků obsažených v databázi sestavené pro účely této práce. V levé části je seznam všech snímků z oblasti vzdáleného snímání, v pravé je seznam ostatních HSI dat. Odkazy na zdroje uvedené ve druhém a osmém sloupci jsou součástí přílohy

této práce. Vybarvené buňky ve sloupcích MATLAB, ENVI a RAW odpovídají staženým formátům pro snímky ve stejném řádku. Soubory označené jako MAT_gt značí Ground Truth (GT) ve formátu .mat. GT je p dimenzionální snímek nesoucí informaci, ve které části snímané scény se nachází daný materiál. Jedná se o informaci pořízenou v konkrétní snímané lokaci. Na základě GT lze posoudit přesnost jednotlivých algoritmů při vyhodnocování na reálných datech. Soubory MAT_wave jsou vektory ve formátu .mat, jejichž hodnoty odpovídají vlnovým délkám pro jednotlivá spektrální pásma HSI snímku.



Obr. 46 - Ukázka HSI snímku Indian Pines a jemu odpovídající GT [77]

Pro ilustraci je na obrázku 46a zobrazený 2D náhled (false color) raw snímku Indian Pines (AVIRIS_IndianPine_EW-line_R), jedná se o letecký HSI snímek pořízený systémem AVIRIS (EW-line značí směr letu, tedy East-West). Snímek je pořízený nad zemědělskými poli Purdue University (uprostřed snímku 46a) v americkém státě Indiana. Rozměry tohoto snímku jsou $614 \times 1848 \times 220$ (x, y, λ). Z této rozsáhlé scény, která byla zaznamenána, byla vybrána menší oblast o ploše přibližně 2×2 míle, kde bylo detailně zaevidováno 16 materiálů a jejich

rozložení (46c). Tomuto rozložení materiálů odpovídá sestavený Ground Truth (46d). Z původního snímku se udělal výřez odpovídající této ploše 2x2 míle. Vyříznutý HSI snímek je v databázi označen pouze jako Indian Pines a jeho rozměry jsou 145×145×220 (x, y, λ). Náhled tohoto výřezu je zobrazený na obrázku 46b. [77]

6.1.1 Parametry a formát dat

Jak již bylo zmíněno v předchozí kapitole, tato práce se zaměřuje na analýzu HSI snímků v programu Matlab. Z toho důvodu budou v této části popsány pouze HSI snímky formátu .mat (součástí databáze je i .pdf soubor obsahující návod na nahrání ENVI souborů do Matlabu, případně na webu mathworks.com lze dohledat k tomu určené toolboxe, ale v rámci této práce nebylo využito těchto možností).

Jednotlivé HSI snímky z databáze byly pořízeny různými systémy. Například satelitním systémem EO-1 nebo systémy leteckého vzdáleného snímání AVIRIS či ROSIS-03 (Reflective Optics Spectrographic Imaging System). Tyto systémy se vzájemně liší technologií i podmínkami snímání (nadmořská výška, zobrazovací úhel, aj.) proto mají jednotlivé HSI snímky různé parametry.

Kromě rozdílných parametrů se také snímky liší množstvím přiložených informací. Zatím co data Indian Pines obsahují snímky HSI i GT, vektor vlnových délek a dokonce i podrobné informace o místě snímání (včetně fotodokumentace snímaných povrchů), tak jiná data obsahují pouze HSI snímek s minimem dalších informací, které je nutné obtížně dohledat.

Většina snímků byla pořízena v podobném spektrálním rozsahu (přibližně 0,4–2,5 μm), počet spektrálních pásem se u stažených remote sensing snímků pohybuje mezi 100 až 230 pásmy (Např. Pavia Centre 104 pásem, Salinas 224 pásem), snímky z druhé kategorie mají menší počet pásem (např. Pineapple 49 pásem). U remote sensing snímků se mohou objevit spektrální pásma bez hodnotné informace vlivem šumu, oblačnosti či absorpčních pásem (viz. Obrázek 29 v kapitole 5.1), proto je ještě nutné redukovat tato pásma, např. snímek Salinas_corrected je redukován o 20 pásem a má tudíž 204 pásem, konkrétně jde o pásma číslo: (108–112), (154–167) a 224.

Snímek s největším prostorovým rozlišením je Japonský Chikusei (2517×2335), který spolu se 128 spektrálními pásmy představuje největší soubor formátu .mat v databázi

(1,38 GB). Naopak nejmenší prostorové rozlišení i velikost mají výřezy Salinas-A (83x86, 1,5 MB) a Ankara (63x63, 2,3 MB).

Reálné snímky v databázi mají 2 možné formáty, které byly v rámci této práce označeny jako typ 1 a typ 2. Na obrázku níže je popis těchto formátů zkopírovaný z hlavního skriptu této práce,

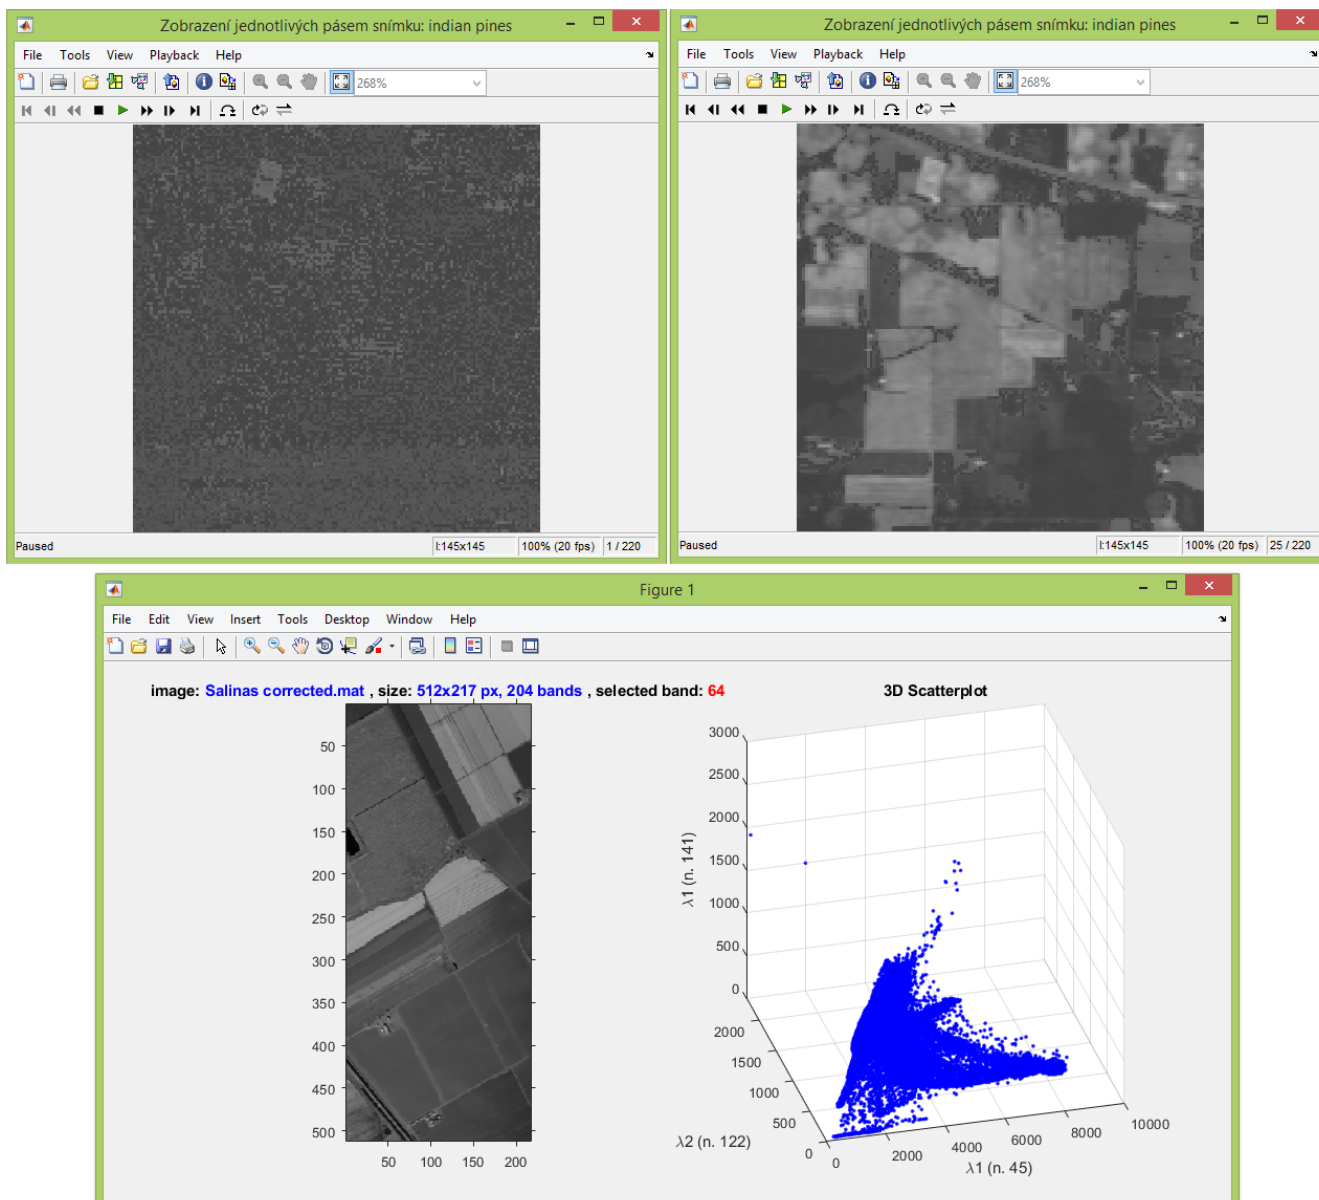
```
% typ 1 (R): hyperspektrální snímek formátu(x,y,N)
%
% typ 2 (R): 1x1 struct:      nRow ... počet řádků (odpovídá hodnotě x)
%                          nCol ... počet sloupců (odpovídá hodnotě y)
%                          nBand ... počet spektrálních pásem (odpovídá N)
%                          Y ... hyperspektrální snímek formátu(N,x*y)
```

Obr. 47 - Popis dvou běžných formátů dostupných HSI dat

kde x a y odpovídá velikosti snímku (počet řádků a sloupců) a N počtu spektrálních pásem. Zatím co v prvním formátu je veškerá informace o HSI snímku v rámci jediné trojrozměrné proměnné datového typu double. Tak ve druhém formátu jsou čtyři proměnné a samotný HSI snímek je v tomto případě dvourozměrná matice, kde každý sloupec odpovídá spektrálnímu vektoru z jednotlivých pixelů.

Každý z těchto formátů má své využití. První formát odpovídá představě HSI snímku jako datacube skládající se ze snímků pro jednotlivá spektrální pásma. Toho lze využít při zobrazování 2D náhledů z jednotlivých spektrálních pásem. To umožňuje vytvořená funkce *Zobrazeni_2D_nahledu*, jejíž vstupem je HSI snímek typu 1, název snímku a požadované spektrální pásmo. Další ilustraci HSI datacube umožňuje funkce *Zobrazeni_snimku_vsech_pasem*, která zobrazuje formou videa postupně všechny 2D náhledy.

Druhý formát je praktičtější pro popis spektrálních vektorů HSI snímku. Tohoto popisu se využívá při aplikaci algoritmů hyperspektrálního rozkladu, jelikož algoritmy HU popsané v této práci pracují pouze se spektrálními vektory, aniž by sledovaly jejich prostorové rozložení. Ilustraci 3D bodového grafu všech spektrálních vektorů HSI snímku umožňují funkce *Zobraz_3D_Scatterplot* a *Zobraz_3D_Scatterplot_real_data*, které se vzájemně liší pouze tím, že první jmenovaná funkce zobrazuje také polohu endmembers, která je známá pro synteticky vytvořená data. Tyto funkce slouží pouze pro ilustraci, přičemž osy x, y a z odpovídají indexům vlnových délek nastavených na vstupu. Pro převod mezi formáty typu 1 a typu 2 byly sestavené jednoduché funkce *Prevod_na_typ1* a *Prevod_na_typ2*.



Obr. 48 - Možnosti zobrazení HSI snímku. Nahoře je ukázka 2D náhledu 1. a 25. pásma snímku Indian Pines pomocí funkce `Zobrazeni_snimku_vsech_pasem`. Z obrázku vlevo je patrné, že informace z prvního pásma je znehodnocená šumem. Dole vlevo je zobrazen 2D náhled HSI snímku Salinas na 64. spektrálním pásmu (funkce `Zobrazeni_2D_nahledu`). Vpravo je 3D bodový graf tohoto snímku (funkce `Zobraz_3D_Scatterplot_real_data`)

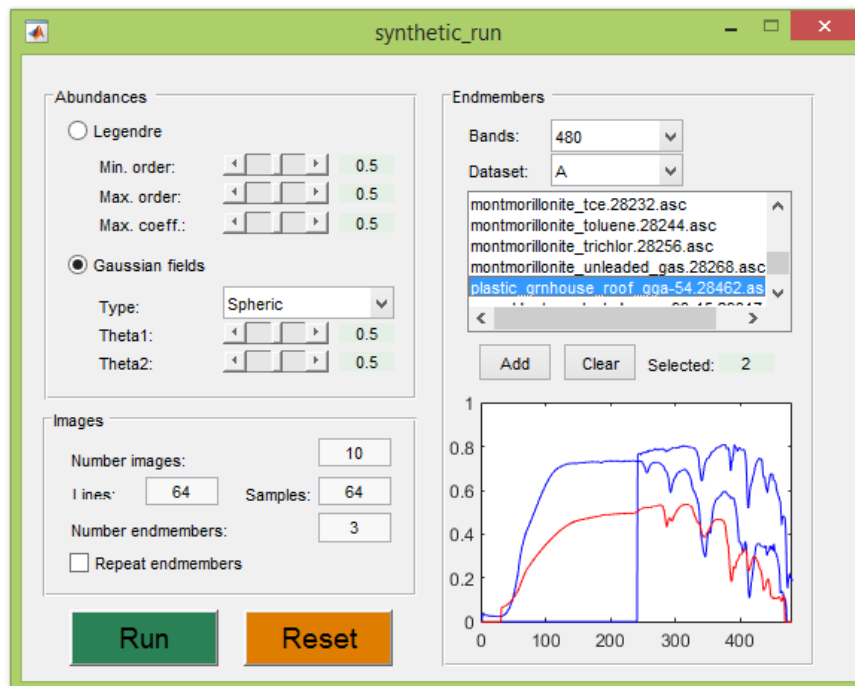
6.2 Synteticky vytvořené HSI snímky

Syntéza je vhodný nástroj pro testování vlastností a chování jednotlivých algoritmů. Umožňuje umělé vytvoření HSI snímků s přesně definovanými parametry. V této práci byly využity dvě dostupné možnosti syntézy HSI dat. Zprvce byl využit toolbox do Matlabu, který je součástí projektu s názvem HYDRA. [78] Jako druhá možnost syntézy HSI dat byla využita funkce `spectMixGen`, která je součástí přílohy článku hyperspectral unmixing overview. [61]

6.2.1 Synthesis tools package (HYDRA)

Jedná se o toolbox do Matlabu umožňující syntézu HSI dat dle definovaných parametrů. Tento toolbox je součástí projektu HYDRA (HYperspectral Data Retrieval and Analysis), vytvořený výzkumnou skupinou Computational Intelligence Group Španělské university of the Basque Country (UPV / EHU). [78]

Součástí toolboxu je grafické uživatelské rozhraní (GUI) pro jednoduché nastavení parametrů a spuštění syntézy. Toto rozhraní se spouští pomocí funkce *synthetic_run*.



Obr. 49 - GUI pro syntézu HSI snímku vytvořené v rámci projektu HYDRA (UPV / EHU) [78]

Grafické rozhraní se skládá ze tří částí: Abundances, Images a Endmembers. V první části lze zvolit způsob, jakým se vytvoří rozložení materiálů ve snímku (tvorba abundances). K tomu lze využít jednu ze dvou nabízených metod vytvoření náhodných průběhů abundances (Legendre a Gaussian fields), včetně nastavení odpovídajících parametrů.

Ve druhé části se nastavují parametry výstupního snímku. Lze nastavit prostorové rozlišení (počet řádků a sloupců) a počet obsažených materiálů. Také je zde možnost, aby se během jediné syntézy vytvořil nastavený počet snímků se stejnými parametry.

Poslední částí je volba materiálů. Zde je nejprve na výběr počet spektrálních pásem. Poté se zobrazí seznam materiálů s požadovaným počtem spektrálních pásem obsažených v dostupné spektrální knihovně (USGS, viz následující kapitola 6.2.2). Z těchto materiálů lze

zvolit, které budou obsaženy ve výstupním HSI snímku. Po spuštění syntézy se vygeneruje nastavený počet snímků s definovanými parametry do aktuální pracovní složky. Výstupní HSI snímky synthesis toolboxu mají stejný formát jako reálné snímky označené jako typ 1, ale jsou navíc doplněny o matice endmembers a abundances. Na obrázku 51 je 2D náhled a 3D bodový graf vygenerovaného snímku pomocí tohoto toolboxu. Na obrázku 52 jsou vykresleny spektra jednotlivých endmembers a jím odpovídající abundances.

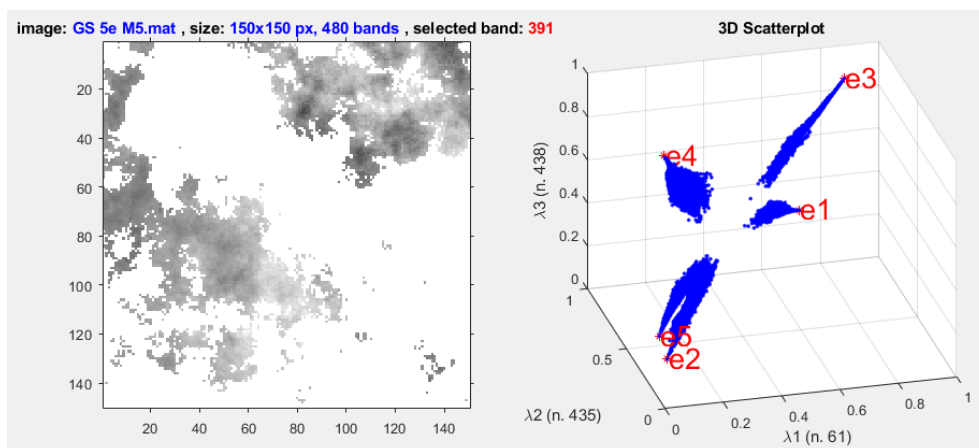
```

% typ 3 (S): 1x1 struct:      endmembers ... matice míchání formátu (p,N),
%                               abundancies ... procentuální zastoupení endmembers
%                               v každém pixelu formátu (x,y,p)
%                               syntheticImage ... syntetický hyperspektrální
%                               snímek formátu(x,y,N)

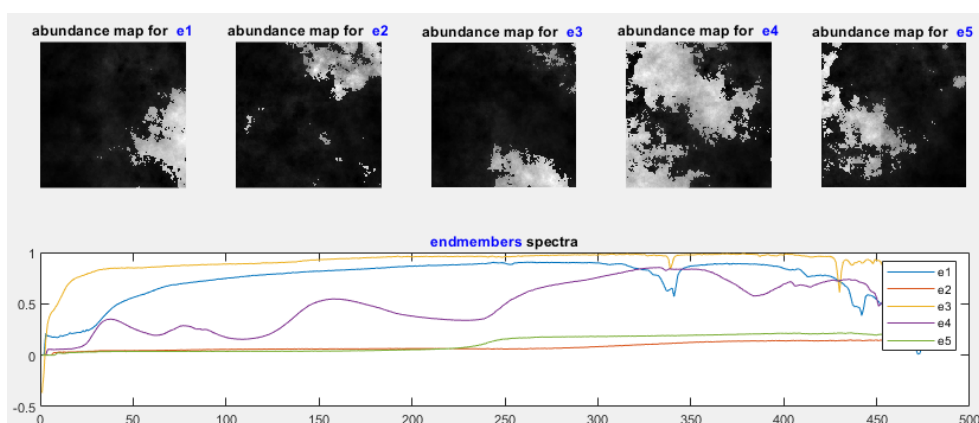
% Význam proměnných:
% x = počet řádků, y = počet sloupců, N = počet spektrálních pásem,
% p = počet endmembers

```

Obr. 50 - Popis formátu synteticky vytvořených dat



Obr. 51 - 2D náhled syntetického HSI snímku na 391. spektr. pásmu (funkce Zobrazeni_2D_nahledu). Vpravo je 3D bodový graf tohoto snímku (funkce Zobraz_3D_Scatterplot)



Obr. 52 - Spektra jednotlivých endmembers a jím odpovídající abundances pro synteticky vygenerovaný HSI snímek (funkce Zobrazeni_endmembers_a_abundances)

Pro rozšíření možností syntézy HSI snímků byla vytvořena funkce přidávající šum (*Pridani_sumu*) podle požadované hodnoty odstupe signálu od šumu (SNR) v dB. V této funkci se nejprve vypočítá výkon vstupního HSI snímku P_s podle vzorce (se zjednodušeným zápisem):

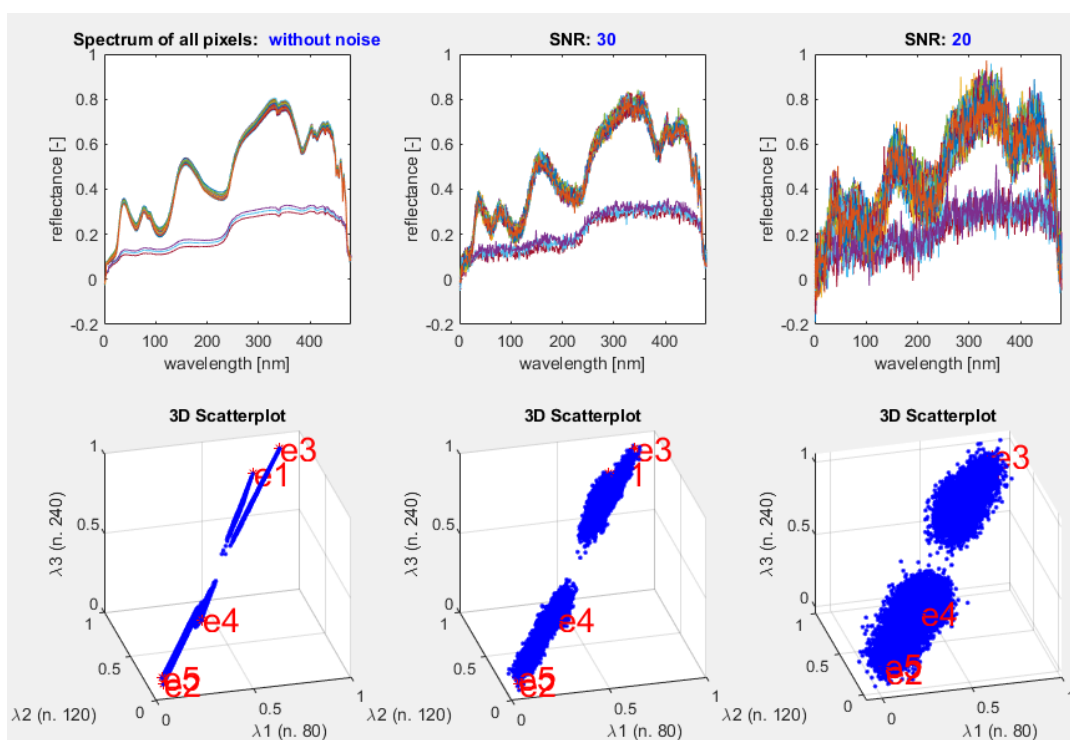
$$P_s = \frac{1}{n} \sum_{x,y,\lambda} b^2 \quad (12)$$

kde b představuje hodnoty jednotlivých buněk celé datacube HSI snímku (x, y, λ) a n jejich celkový počet ($x \cdot y \cdot \lambda$). V následujícím kroku se určí požadovaný výkon šumu P_n :

$$P_n = \frac{P_s}{10^{\frac{SNR}{10}}} \quad (13)$$

V posledním kroku se vygeneruje matice **noise** (pomocí funkce *randn*) o rozměrech odpovídajících původnímu HSI snímku a s Gaussovým rozdělením. Zápis v Matlabu: *randn(size(HSI))*. Tato matice o definovaném výkonu P_n se přičte k původnímu hyperspektrálnímu snímku.

$$HSI_{SNR} = \sqrt{P_n} * \mathbf{noise} + HSI \quad (14)$$



Obr. 53 - Vliv šumu na syntetizovaný HSI snímek (skript *zobrazeni_vlivu_sumu*).

Na obrázku 53 je zobrazený vliv šumu na syntetizované HSI snímky (skript *zobrazeni_vlivu_sumu*). V prvním řádku jsou vykreslena spektra všech pixelů daného snímku. Ve druhém řádku jsou bodové grafy zobrazující všechny spektrální vektory ve 3D prostoru. Charakteristiky v prvním sloupci odpovídají původnímu snímku bez šumu, ve druhém sloupci jsou charakteristiky snímku s odstupem signálu od šumu 30 dB a ve třetím s hodnotou SNR 20 dB.

Ačkoliv tento synthesis toolbox poskytuje různé možnosti při generování HSI dat, tak není nejvhodnější pro účely testování HU algoritmů popsaných v této práci. Sice byla dodatečně vytvořená funkce na přidání šumu, ale stále chybí možnost generování snímku bez pure pixels, možnost aby snímky obsahovaly outliers či volba míry zahuštění dat. Naopak generování HSI dat podle tvaru abundances je v tomto případě nadbytečná možnost, jelikož všechny testované algoritmy vyhodnocují na základě rozložení spektrálních vektorů a jejich konvexního obalu. Z toho důvodu byla dohledána funkce *spectMixGen*, která je součástí přílohy ke článku hyperspectral unmixing overview. [61]. Tato funkce umožňuje generování syntetických HSI dat včetně volby požadovaných parametrů. Výstupní HSI snímky z obou popsaných metod jsou zobrazeny na konci kapitoly 6.2.3 na obrázku číslo 57.

6.2.2 Spektrální knihovna

Součástí synthesis toolboxu [78] je USGS (United States Geological Survey) spektrální knihovna. [79] Tato knihovna obsahuje spektra odraženého záření (reflectance spectrum) od různých materiálů změřená v laboratorních podmínkách. Využití spektrální knihovny připadá převážně v oblasti vzdáleného snímání pro identifikaci materiálů, kde spektra uložená v této knihovně slouží jako reference. Avšak spektrální knihovnu lze také využít i při generování syntetických HSI.


Použitá verze spektrální knihovny (splib06a) obsahuje stovky reflektance spekter různých materiálů, změřených v rozsahu pokrývající oblast vlnových délek 0,2–3,0 μm (přesný rozsah záleží na použitém spektrometru). Materiály jsou v této databázi rozděleny do 6 kategorií: Artificial, Coatings, Liquids, Minerals, Soils a Vegetation.

Reflektance spektra obsažená v této databázi jsou ve formátu .asc. Pro účely generování HSI dat pomocí funkce *spectMixGen* byl napsán skript v Matlabu umožňující vytvoření spektrální knihovny ve formátu .mat (skript *create_e_database*) obsahující vybrané materiály

ze složky USGS Spectral library, jenž je součástí synthesis toolboxu. V rámci tohoto skriptu je využita funkce ze synthesis toolboxu (*getEndmembers*) umožňující nahrání všech .asc souborů z definované složky do workspace v Matlabu.

Na začátku skriptu je třeba nastavit, jaké skupiny materiálů budou nahrány do databáze, např. všechny materiály: `database_sets = {'A','C','L','M','S','V'}` nebo jen vybrané kategorie: `database_sets = {'M','V'}`. Také je třeba nastavit požadovaný počet spektrálních pásem reflektance spekter (např. 224, 480, 2151, aj.). Podle zvolených parametrů se vytvoří databáze endmembers a uloží se do aktuální složky v odpovídajícím Matlabovém formátu. Výstupní soubor obsahuje pro každý materiál informaci o jeho názvu a reflektance spektru.

Některé hodnoty reflektance ve změřeném spektru byly autory USGS spektrální databáze označeny za špatně změřené a jejich hodnota byla nahrazena číslem $-1,23e+34$. Tato změna není pro účely této práce žádoucí, a proto při každém nahrávání spektrální databáze do workspace jsou v prvním kroku nahrazeny všechny záporné hodnoty číslem 0.



Obr. 54 - Ukázka spekter materiálů z kategorie Artificial o délce 480 spektrálních pásem

Takto vytvořená spektrální databáze je v této práci využita pro generování HSI snímků pomocí funkce *spectMixGen*. A také pro zpětné porovnání odhadnutých endmembers (podle testovaných metod HU) s touto databází a vyhodnocení, zda byly odhadnuty správně.

Jelikož USGS knihovna obsahuje reflektance spektra i pro různé vzorky shodných materiálů, tak byl vytvořen ještě jeden skript pro omezení podobných spekter

(*create_e_database_pruned*). Podobná spektra měla za důsledek, že při porovnávání algoritmů HU v hlavním skriptu (viz kapitola 7) občas docházelo k situaci, při které některý z algoritmů vyhodnotil chybně materiál, přestože odchylka od skutečného materiálu byla nepatrná. Z toho důvodu byla zavedena omezující podmínka vyřazující podobná spektra z databáze. Tuto omezující podmínku představuje velikost spektrálního úhlu θ : [58]

$$\theta = \frac{180}{\pi} \cos^{-1} \left(\frac{\mathbf{v1}^T \times \mathbf{v2}}{\|\mathbf{v1}\|_F \|\mathbf{v2}\|_F} \right) \quad (15)$$

kde $\mathbf{v1}$ a $\mathbf{v2}$ představují spektrální vektory vzájemně porovnávaných materiálů.

Na vstupu tohoto skriptu (*create_e_database_pruned*) se nahraje již vytvořená spektrální databáze. Následuje omezení této databáze podle nastaveného spektrálního úhlu, kdy se porovnají všechny vzájemné úhly jednotlivých materiálů, a v případě je-li některý z úhlů menší, než je nastavená podmínka, tak dojde k vymazání druhého z materiálů s podobným úhlem. Výstupní databáze se uloží do nového souboru v aktuální složce.

Kontrolní výpočet spektrálního úhlu mezi zvolenými spektrálními vektory endmembers:

258	'kaolinite_cm3.11788.asc'	1x480 double
259	'kaolinite_cm5.11846.asc'	1x480 double
263	'kaolinite_kga1.12117.asc'	1x480 double

X ... spektrum 258. materiálu

Y ... spektrum 259. materiálu


Z ... spektrum 263. materiálu

Velikost spektrálních úhlů:

X a Y: 0.81107°

X a Z: 1.3536°

Y a Z: 1.5725°



kaolinite_cm3_crw_0020_rj



kaolinite_cm5_crw_0022_rj



kaolinite_kga1_0237_rj

Obr. 55 – Spektra 3 vybraných vzorků kaolinitu a jejich vzájemné spektrální úhly [79]

6.2.3 Funkce spectMixGen (J. M. Bioucas-Dias)

Tato funkce profesora José Bioucas-Dias z Lisabonské Univerzity [80] umožňuje generování syntetických hyperspektrálních dat s širokými možnostmi nastavení parametrů. Jedinými vyžadovanými vstupy této funkce jsou matice míchání \mathbf{M} (obsahující p endmembers o délce L) a počet spektrálních vektorů výsledného snímku. Kromě toho lze nastavit řada volitelných parametrů, jako jsou: velikost SNR, počet spektrálních vektorů ležících mimo konvexní obal (outliers), možnost zda budou součástí snímku pure pixels nebo maximální množství endmembers připadající na jeden pixel (p_pix).

Pro usnadnění práce s touto funkcí a také pro zajištění stejného formátu dat byl vytvořen skript `generate_synthetic_HSI`. Na začátku tohoto skriptu se nastavuje vstupní spektrální databáze, ze které se vybere buď manuálně či automaticky p endmembers, které se uloží do matice míchání \mathbf{M} . Následuje nastavení ostatních povinných i volitelných parametrů syntézy. V dalším kroku se spustí funkce `spectMixGen` generující syntetický HSI snímek podle nastavených parametrů. Výstupní syntetický snímek se následně upraví tak, aby jeho formát odpovídal formátu syntetických HSI ze synthesis toolboxu. Kromě HSI snímku, matice míchání a abundances se do výstupního souboru uloží ještě informace o použité databázi, nastavených hodnotách syntézy, a také indexy a názvy použitých endmembers (viz screen z Matlabového skriptu a výpis všech parametrů ve workspace viz níže).

```
% Výstupní soubor: OUT_ZZ, kde ZZ ... číslo výstupního snímku
%
% OUT_ZZ | 1x1 struct:
% INPUT_DATABASE ... název použité databáze
% Nastaveni_parametru ... nastavené hodnoty vstupních parametrů (SNR, p, atd.)
% Nazvy_endmembers ... indexy a názvy použitých materiálů při syntéze
% abundancies ... procentuální zastoupení endmembers v každém pixelu
% formátu (x,y,p)
% endmembers ... matice míchání formátu (p,N)
% syntheticImage ... syntetický hyperspektrální snímek formátu(x,y,N)
%
% Význam proměnných:
% x = počet řádků, y = počet sloupců, N = počet spektrálních pásem,
% p = počet endmembers
```

The screenshot shows the MATLAB workspace with three variables:

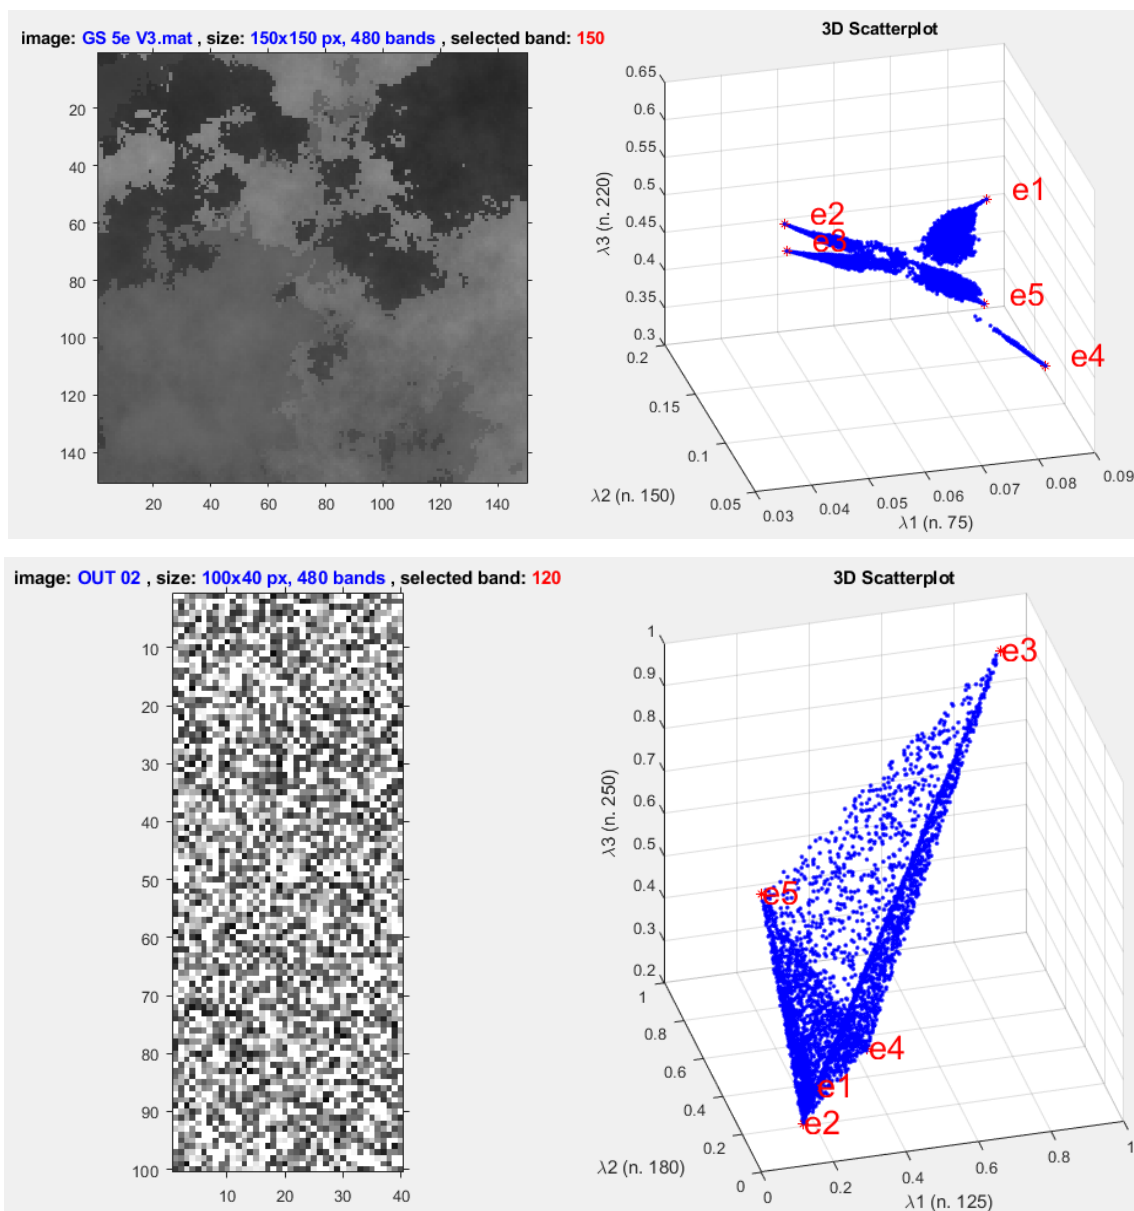
- OUT_01**: Soubor MAT, 14 289 kB. A table with columns Name and Value.
- Nastaveni_parametru**: A table with parameters and their values.
- Nazvy_endmembers**: A table with columns idx and name.

Name	Value
abundancies	100x40x5 double
endmembers	5x480 double
INPUT_DATABASE	'e_database_480_pruned_5.mat'
Nastaveni_parametru	1x1 struct
Nazvy_endmembers	1x1 struct
syntheticImage	100x40x480 double

Parameter	Value
SNR	20
np	4000
p	5
p_pix	3
MAX_PURITY	1
OUTLIERS	0
PURE_PIXELS	'no'
SHAPE_PARAMETER	1

idx	name
1	andradite_hs111.2203...
2	hematite_hs45.9722.a...
3	hypersthene_pyx02.1...
4	jarosite_gds100.11210...
5	fe_hydroxide_su93-10...

Obr. 56 - Popis všech součástí výstupního souboru ze skriptu `generate_synthetic_HSI`



Obr. 57 - Porovnání syntetických snímků vygenerovaných podle dvou metod syntézy popsanych v této práci

Horní snímek na obrázku 57 je vygenerovaný pomocí synthesis toolboxu, dolní pomocí funkce *spectMixGen*. Oba snímky se skládají z pěti endmembers a byly vygenerovány bez šumu. Na 3D bodovém grafu těchto snímků je patrné, že druhá zmiňovaná metoda syntézy HSI dat umožňuje vytvoření snímků s větší mírou zahuštění dat, a tedy takto vytvořené HSI snímky představují větší výzvu pro algoritmy hyperspektrálního rozkladu. Navíc při syntéze ve druhé metodě je k dispozici mnohem více parametrů, které mohou ovlivnit rozložení spektrálních vektorů ve spektrálním prostoru (outliers, pure pixels, parametr *p_pix*, *max_purity*, atd.).

7 Hlavní skript

Pro porovnání algoritmů hyperspektrálního rozkladu na reálných či syntetických datech byl sestaven ucelený skript *Main_script_TymesP*. Tento skript umožňuje nahrání HSI snímku, na kterém se pomocí vybraných metod hyperspektrálního rozkladu odhadnou průběhy materiálů, ze kterých se skládá. A následně se vyhodnotí přesnost těchto odhadů. Skript se skládá ze 6 částí, které jsou popsány v následujících kapitolách.

7.1 Výběr a nahrání vstupních dat

Tento skript funguje pro hyperspektrální snímky uložené ve všech formátech popsaných v této práci (formáty dat označené jako typ1, typ2 pro reálné a typ 3 pro syntetické snímky).

Po spuštění skriptu se otevře dialogové okno pro výběr vstupní složky. Poté, co uživatel vybere a potvrdí vstupní složku, tak se v command window zobrazí její název a vypíše se dotaz, zda daná složka obsahuje reálné (R) či syntetické (S) snímky. Výběr se provádí vypsáním písmene R nebo S do command window. V následujícím kroku se zobrazí seznam všech souborů formátu .mat obsažených v dané složce. Nyní je potřeba uvést číslo snímku, se kterým se bude nadále pracovat. Vybraný snímek se nahraje do workspace. V případě reálných dat, pokud existuje, tak se také nahraje i odpovídající snímek ground truth.

7.2 Zobrazení vstupních dat

```
% figure 1 (pro R i S):  
%   a) Náhled HSI snímku v jediném spektrálním pásmu (selected band)  
%   b) 3D Scatterplot spektrálních vektorů pro všechny pixely,  
%       3 osy odpovídající spektrálním pásmům (lambda1,lambda2,lambda3)  
  
% figure 2 (pro R i S):  
%   Zobrazení zaznamenaných spekter na jednotlivých pixelech  
%   Počet zobrazených spekter - podle nastaveného limitu:  
%       limit = 100;  
  
% figure 3 (pro S):  
%   a) Abundances pro jednotlivé endmembers  
%   b) Spektrální znaky endmembers
```

Obr. 58 – Možnosti zobrazení vstupního HSI snímku

Druhá část je věnovaná zobrazení vstupních dat. Zde záleží na vstupním nastavení skriptu. Úvodní zobrazení lze úplně vypnout, případně lze zvolit, které z možných obrázků se zobrazí. Úvodní nastavení se provádí zápisem hodnot 1 (aktivování) nebo 0 (deaktivování) do odpovídajících proměnných na začátku skriptu (např. nastavení pro zobrazení druhého obrázku:


vykreslit_figure_2 = 1). V nastavení lze také vybrat, zda se parametry zobrazení vyberou automaticky či manuálním vypsáním konkrétních hodnot.

Možnosti zobrazení vstupního HSI snímku jsou popsány na obrázku 58.

7.3 Redukce dimenze (HYSIME)

Před provedením hyperspektrální rozkladu, je zapotřebí odhadnout počet endmembers, a také redukovat dimenzi vstupního snímku. K tomu je využit algoritmus HySime (Hyperspectral Signal identification by minimum error, autoři J. M. Bioucas-Dias a J. M. P. Nascimento). [61] [81] Jedná se o plně automatický algoritmus, který nezávisí na žádných „ladících“ parametrech.

V rámci tohoto algoritmu je nejprve určena korelační matice signálu a šumu (defaultně je nastaven aditivní šum) pomocí funkce *estNoise*. Následně je hledán set vlastních čísel, který nejlépe reprezentuje podprostor vstupního snímku (funkce *hysime*). Dimenze podprostoru je určena na základě minimalizace součtu výkonu odchylky projekce a výkonu šumu. Výkon odchylky je klesající funkce dimenze podprostoru, naopak výkon šumu je funkce rostoucí, jak je znázorněno na obrázku 59. Výstupem této funkce je odhadnutý počet endmembers p .



Obr. 59 - Princip algoritmu HySime: hledání minimální hodnoty součtu výkonu chyby projekce a výkonu šumu v závislosti na velikosti dimenze p . [81]

V posledním kroku je provedena projekce vstupního hyperspektrálního snímku na identifikovaný podprostor o dimenzi p (funkce *affineProj*). Výstupem je hyperspektrální snímek s redukovanou dimenzí \mathbf{Y}_p , a také matice zobrazení \mathbf{U}_p .

7.4 Algoritmy hyperspektrálního rozkladu


V této části skriptu jsou aplikovány vybrané metody hyperspektrálního rozkladu. Součástí tohoto skriptu jsou pure pixel based algoritmy: PPI, VCA, N-FINDR, AVMAX a MV based algoritmy: SISAL a NMF-QMV (se třemi variantami MV regularizátorů). V úvodním nastavení skriptu lze vybrat, které algoritmy budou spuštěny.

Vstupem vybraných algoritmů je hyperspektrální snímek Y_p a odhadnutý počet endmembers p . Výstupem je odhadnutá matice míchání M a změřený výpočetní čas.

7.5 Zobrazení výstupních dat

Po realizaci hyperspektrálního rozkladu pomocí vybraných metod následuje grafické zobrazení výsledků. Na jednom obrázku (ve skriptu označeném jako Figure 4) se vykreslí 2D bodový graf všech spektrálních vektorů vstupního snímku. Součástí tohoto grafu je také zobrazení spektrálních vektorů odhadnutých endmembers podle jednotlivých metod (vzájemně rozlišené barevnými symboly). V případě syntetického vstupního snímku je zobrazena i poloha originálních endmembers (označeny černými kroužky).

Druhým obrázkem (Ve skriptu značeným jako Figure 5) je vykreslení průběhů odhadnutých endmembers. V případě syntetických dat, je součástí i průběh skutečných endmembers.



Obr. 60 – Vlevo je 2D projekce HSI snímku včetně odhadnutých a skutečných endmembers (Figure 4)
Vpravo jsou průběhy odhadnutých a skutečných endmembers (Figure 5)

V rámci této práce jsou Figure 4 a Figure 5 vykresleny pomocí funkcí `Zobrazeni_projekce_endmembers` a `Zobrazeni_spektra_endmembers` (tato funkce má

2 varianty, jednu pro reálné a druhou pro syntetické snímky). Tato zobrazení byla vytvořena modifikací skriptu *geo_unmixing*, jenž je součástí přílohy ke článku *unmixing overview*. [61]

Při zobrazování je využita matice \mathbf{U}_p tak, aby zobrazovaná data ležela ve stejném prostoru. Například Figure 4 pro syntetická data: Odhadnuté matice míchání \mathbf{M} , leží již v definovaném podprostoru. Proto pro zobrazení jednotlivých endmembers stačí vykreslit závislost vybraných spektrálních pásem. Pro zobrazení závislosti mezi 1. a 2. spektrálním pásmem lze napsat: `plot(M(1,[1:p 1]), M(2,[1:p 1]))`. Naopak původní matici míchání \mathbf{M}_{true} je nutné převést na odpovídající podprostor $\mathbf{M}_{true} = \mathbf{U}_p' \times \mathbf{M}_{true}$, a následně lze vykreslit závislost prvního a druhého spektrálního pásma: `plot(Mtrue(1,[1:p 1]), Mtrue(2,[1:p 1]))`.

7.6 Vyhodnocení pro syntetická data

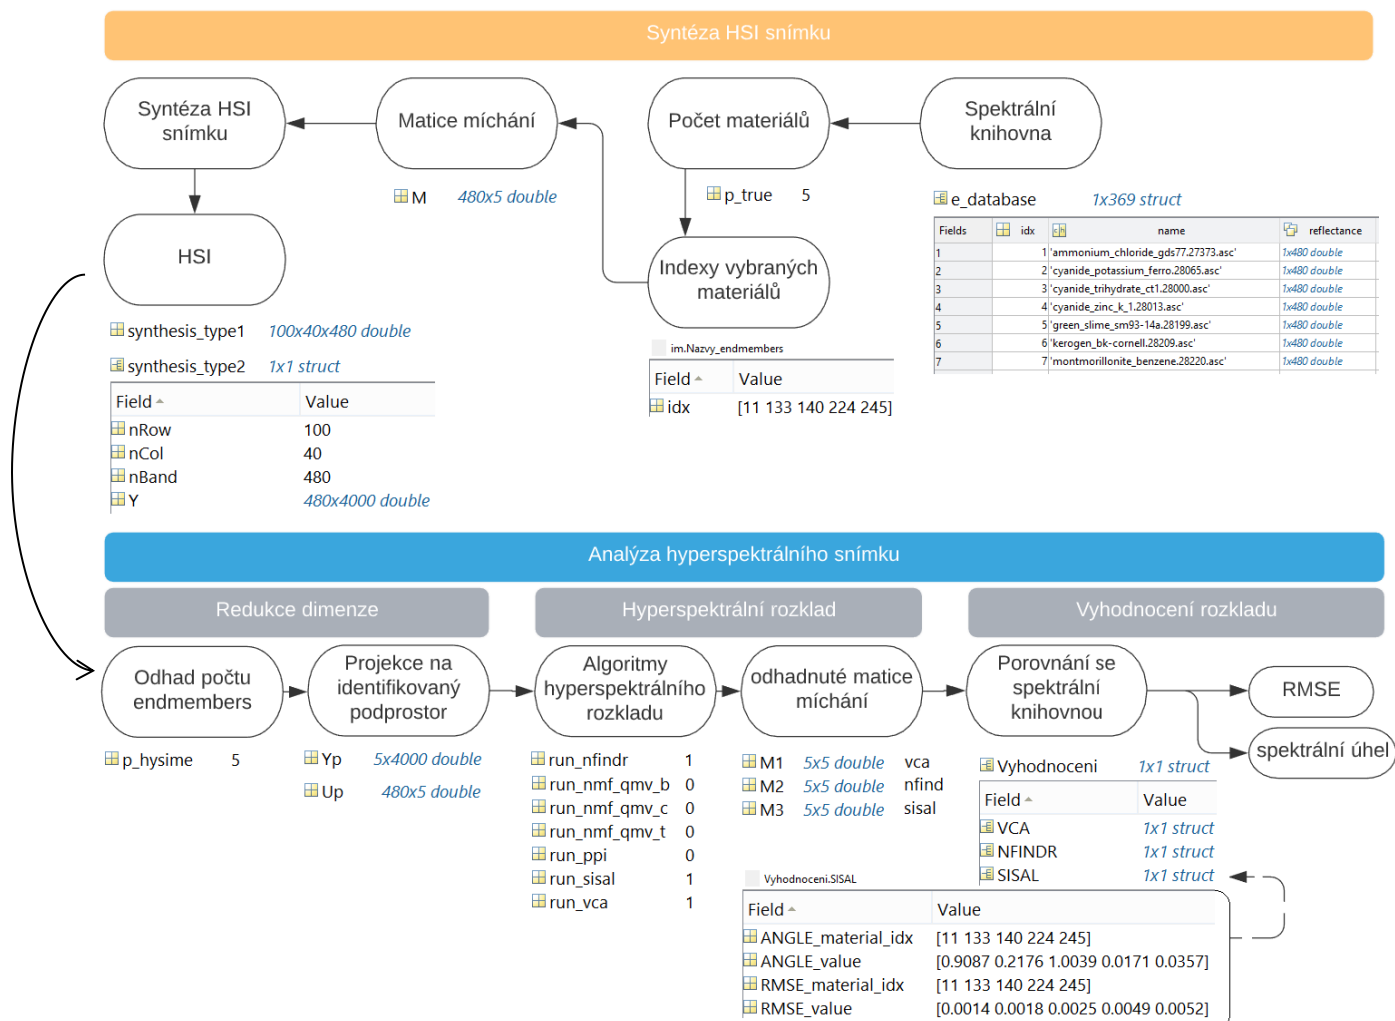
V poslední části jsou porovnávána spektra endmembers odhadnutá podle vybraných algoritmů hyperspektrálního rozkladu (sloupce matice \mathbf{M}) se všemi spektry obsaženými ve vybrané spektrální knihovně. Porovnává se na základě dvou kritérií: Spektrální úhel a RMSE.

Výstupem tohoto porovnání pro každý odhadnutý endmember je index materiálu ze spektrální knihovny, který svírá nejmenší spektrální úhel s vybraným endmemberem, a také index materiálu, který má nejmenší odchylku RMSE (Root mean Square Error) od daného endmemberu.

Před provedením tohoto porovnání je nutné nahrát odpovídající spektrální knihovnu do workspace (aby odpovídaly indexy materiálů). Je-li vstupní snímek vygenerovaný pomocí funkce `spectMixGen` (viz kapitola 6.2.3), tak se nahraje odpovídající spektrální knihovna na základě proměnné `INPUT_DATABASE`, která je součástí vstupního snímku. Neobsahuje-li vstupní hyperspektrální snímek informaci o použité spektrální knihovně, tak se předpokládá, že byla použita druhá metoda pro generování (kapitola 6.2.1) a nahraje se defaultní knihovna `e_database_480.mat` (všechna spektra materiálů z knihovny `splib06a` o počtu 480 spektrálních pásem ve formátu `.mat`). V tomto případě je ještě nutné do command window uvést indexy použitých endmembers.

Pro porovnání spekter byla vytvořena funkce `Porovnaní_s_databazi`, jejímž vstupem je matice míchání \mathbf{M} a spektrální knihovna. Výstup této funkce obsahuje pro každé kritérium zvlášť indexy materiálů s největší shodou pro jednotlivé odhadnuté endmembers (indexy materiálů s nejmenším vzájemným spektrálním úhlem a indexy materiálů s minimální hodnotou

RMSE), včetně odpovídajících hodnot (minimální spektrální úhel a minimální odchylka RMSE). Pro porovnání na základě RMSE je využita funkce *SpectraMatch* [82]. Velikost vzájemného spektrálního úhlu je vypočítána podle vzorce (15).



Obr. 61 – Shrnutí porovnání algoritmů hyperspektrálního rozkladu na syntetických HSI

Testování algoritmů hyperspektrálního rozkladu (HU) na syntetických hyperspektrálních snímcích je shrnuto na obrázku 61. Nejprve se vytvoří HSI snímek s definovanými parametry, obsahující spektra vybraných p (p_true) materiálů.

Ukázkové hodnoty odpovídají syntéze a analýze HSI snímku s názvem OUT_04.mat (100×40 pixelů, 480 spektrálních pásem, snímek se skládá z 5 spekter vybraných materiálů, snímek je bez čistých pixelů, obsahuje outliers, SNR 50 dB).

V analýze se nejprve odhadne počet materiálů obsažených v daném snímku. Při správném vyhodnocení je odhadnutý počet materiálů roven počtu zvolenému při syntéze

($p_hysime = p_true$). V následujícím kroku dojde k redukci dimenze hyperspektrálního snímku za účelem snížení množství dat před aplikováním jednotlivých algoritmů HU (vstupní snímek $\mathbf{Y} = 480 \text{ pásem} \times 4000 \text{ pixelů}$, snímek s redukovanou dimenzí $\mathbf{Yp} = 5 \text{ pásem} \times 4000 \text{ pixelů}$, matice \mathbf{Up} je matice zobrazení $\mathbf{Yp} = \mathbf{Up}' \times \mathbf{Y}$). Nyní se na snímek \mathbf{Yp} aplikují vybrané algoritmy HU, jejichž výstupem je odhadovaná matice míchání \mathbf{Mx} o rozměrech $p_hysime \times p_hysime$. Sloupce matic \mathbf{Mx} tvoří odhadnuté materiály (endmembers) tvořící vstupní HSI snímek.

V posledním kroku je porovnávána přesnost odhadu materiálů aplikovaných algoritmů hyperspektrálního rozkladu. Odhadnuté matice míchání jsou nejprve převedeny zpět do původního prostoru ($\mathbf{Mx} = \mathbf{Up} \times \mathbf{Mx}$) tak, aby měly matice \mathbf{Mx} a \mathbf{M} shodné rozměry (480×5). Přesnost odhadu je otestována pomocí srovnání spekter odhadnutých materiálů se všemi spektry materiálů obsaženými v použité spektrální knihovně (hledání minima RMSE a vzájemného spektrálního úhlu). Výstupem porovnání je index materiálu ze spektrální knihovny, který má s odhadnutým endmemberem nejmenší vzájemný spektrální úhel nebo nejmenší odchylku RMSE. Algoritmus pracuje správně, pokud indexy všech odhadnutých materiálů odpovídají indexům materiálů použitých při syntéze. Na obrázku 61 jsou zobrazeny výsledky porovnání pro algoritmus SISAL. Odhadnuté materiály odpovídají skutečným pro obě použitá kritéria (indexy materiálů: 11, 133, 140, 224 a 245).

Výsledky porovnání pro všechny zvolené algoritmy HU se uloží do proměnné *vyhodnoceni*. Na základě této proměnné se vytvoří 4 tabulky shrnující dosažené výsledky (V textu označené jako tabulky 4 až 7). Tyto tabulky se po spuštění skriptu vypíší do command window a zároveň se uloží do excelovské tabulky (.xlsx) v aktuální složce (je-li v úvodním nastavení skriptu povoleno ukládání: *ukladat_tabulky* = 1).

První tabulka (*Puvodni_endmembers*) obsahuje seznam indexů a k nim odpovídajících názvů použitých spekter materiálů při syntéze.

Tabulka 4: Původní endmembers

Indexy	Puvodni_materialy
11	'renyolds_tunnel_sludge_sm93-15.29317.asc'
133	'epidote_gds26.7546.asc'
140	'galena_s102-17.7943.asc'
224	'muscovite_il1107.15566.asc'
245	'opal_tm8896.17216.asc'

Do druhé tabulky (*Vyhodnoceni_table*) jsou uloženy celkové výsledky porovnání pro všechny zvolené algoritmy HU (Převod proměnné *vyhodnoceni* do tabulky).

Tabulka 5: Vyhodnocení porovnání algoritmů HU

ALG	ANGLE_material_idx	ANGLE_value	RMSE_material_idx	RMSE_value
'VCA_1'	44	6.0766	4	0.070231
'VCA_1'	135	4.9391	135	0.038998
'VCA_1'	140	7.967	140	0.0090726
'VCA_1'	224	3.3104	224	0.036929
'VCA_1'	245	0.55739	252	0.035239
'NFINDR_1'	135	4.6633	98	0.025223
'NFINDR_1'	224	1.1332	135	0.03813
'NFINDR_1'	233	10.558	159	0.077791
'NFINDR_1'	245	0.22929	259	0.015467
'NFINDR_1'	259	8.1811	303	0.04575
'SISAL'	11	1.0566	11	0.0015806
'SISAL'	133	0.29497	133	0.0020915
'SISAL'	140	0.48602	140	0.0012511
'SISAL'	224	0.017851	224	0.0047179
'SISAL'	245	0.051036	245	0.005604

Třetí tabulka (*Ziskany_endmembers_shoda_s_puvodnimi*) obsahuje hodnoty spektrálních úhlů nebo odchylek RMSE pouze pro správně určené materiály.

Tabulka 6: Přesná shoda materiálů (dle indexu)

VCA_1	NFINDR_1	SISAL
''	''	'ANGLE (1.0566°), RMSE (0.0015806)'
''	''	'ANGLE (0.29497°), RMSE (0.0020915)'
'ANGLE (7.967°), RMSE (0.0090726)'	''	'ANGLE (0.48602°), RMSE (0.0012511)'
'ANGLE (3.3104°), RMSE (0.036929)'	'ANGLE (0.22929°)'	'ANGLE (0.017851°), RMSE (0.0047179)'
'ANGLE (0.55739°)'	'ANGLE (8.1811°)'	'ANGLE (0.051036°), RMSE (0.005604)'

Poslední tabulka (*Celkove_porovnaní*), vychází z Tabulky III. a obsahuje vyhodnocení pouze pro přesně určené materiály. Zde je zobrazeno, kolik materiálů bylo přesně určeno na základě kritéria spektrálního úhlu a kolik za využití kritéria RMSE. Ze správně určených materiálů jsou také zobrazeny hodnoty s minimálními a maximálními odchylkami. A také hodnota průměrné odchylky. Součástí této tabulky je také informace o výpočetním času jednotlivých algoritmů.

V případě povolení ukládání těchto tabulek do excelu se tabulka IV. uloží na první list, tabulky I. a III. na list druhý a tabulka II. na poslední, třetí list.

Tabulka 7: Celkové porovnání

	<u>angle_estimated_endmembers</u>	<u>min_angle</u>	<u>max_angle</u>	<u>mean_angle</u>	<u>compute_times</u>
VCA_1	3	0.557	7.967	3.945	0.002
NFINDR_1	2	0.229	8.181	4.205	0.025
SISAL	5	0.018	1.057	0.381	0.123
	<u>RMSE_estimated_endmembers</u>	<u>min_RMSE</u>	<u>max_RMSE</u>	<u>mean_RMSE</u>	
VCA_1	2	0.0091	0.0369	0.023	
NFINDR_1	0	NaN	NaN	NaN	
SISAL	5	0.0013	0.0056	0.003	

7.7 Konec skriptu

Po vyhodnocení reálných či syntetických dat následuje uložení dosažených výsledků. Kromě .xlsm tabulky pro syntetická data lze také uložit zobrazené figures. Tuto možnost lze zapnout či vypnout v úvodním nastavení (*ukladat_figures = 1/0*).

V případě povoleného ukládání se ve složce se vstupními daty vytvoří nová složka s názvem XXX_figures (XXX odpovídá názvu nahraného vstupního snímku). Do této složky se automaticky uloží všechny zobrazené figures pojmenované jako figYYY_XXX (YYY značí pořadová čísla figures). V případě, že již daná složka obsahuje takto vygenerované obrázky pro vybraný HSI snímek, tak dojde k jejich přepsání. Pokud není žádoucí přepsání existujících obrázků, tak je vhodné před spuštěním skriptu možnost ukládání figures vypnout nebo již existující obrázky zálohovat.

Na úplném závěru skriptu se v command window vypíše dotaz, zda uživatel chce znovu okamžitě spustit skript, a případně zda chce pracovat se stejnými daty či jinými. V případě souhlasu stačí napsat „Y“ (nebo: y, yes, ano), jakýkoliv jiný znak znamená nesouhlas. Pro pokračování se stejnými daty (stejná složka, je předpokládán stejný typ dat S/R) je tedy třeba dvakrát potvrdit dotaz pro opakování skriptu, ale s výběrem nové vstupní složky je zapotřebí nejprve potvrdit znakem „Y“, a poté napsat jakýkoliv jiný znak, např. „N“. Možnost opakování skriptu byla přidána pro urychlení testování na větším množství vstupních dat.

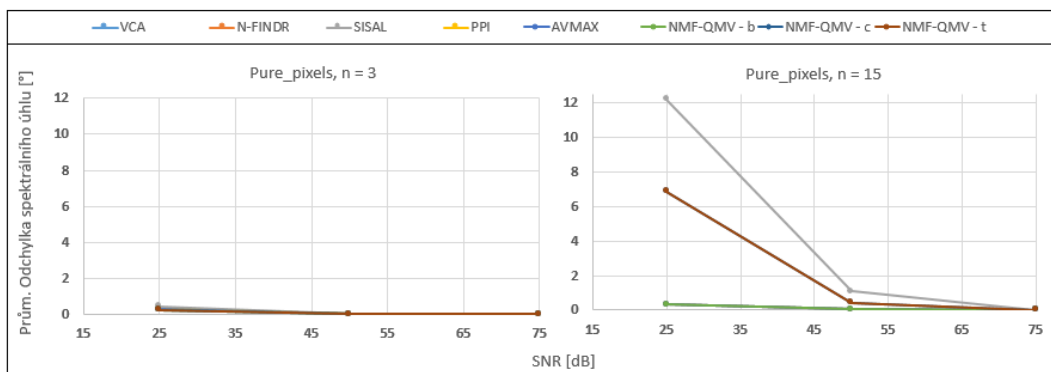
8 Testování algoritmů HU

8.1 Syntetická data

Pro otestování algoritmů hyperspektrálního rozkladu byl nejprve proveden shrnující test zaměřující se na správné vyhodnocení endmembers. Pro účely tohoto testu byla sestavena sada syntetických snímků o rozměrech $100 \times 100 \times 480$ (x , y , λ). Vygenerované snímky se s definovaným krokem liší velikostí odstupů signálu od šumu, a také počtem endmembers, ze kterých se jednotlivé snímky skládají. Tento test byl proveden na dvou sadách snímků. Všechny HSI snímky z první testovací sady obsahují pure pixels, naopak snímky ze druhé sady je neobsahují a navíc mají nastavených 5 outliers. Výsledky porovnání podle kritéria spektrálního úhlu jsou zobrazeny níže (součástí tohoto textu jsou pouze vybrané výsledky jednotlivých testů, veškerá data k vyhodnocení testů jsou součástí přílohy na CD). Sloupce označené zkratkou est. značí počet správně odhadnutých endmembers a sloupce mean obsahují průměrné hodnoty odchylky spektrálního úhlu ve stupních.

Tabulka 8: Shrnující test na snímcích s pure pixels

Test_HU_Algs_01																		
n	SNR	Název	VCA		N-FINDR		SISAL		PPI		AVMAX		NMF-QMV - b		NMF-QMV - c		NMF-QMV - t	
			est	mean	est	mean	est	mean	est	mean	est	mean	est	mean	est	mean	est	mean
3	75	test01_01	3	0,001	3	0,001	3	0,008	3	0,001	3	0,001	3	0,001	3	0,001	3	0,001
	50	test01_02	3	0,012	3	0,012	3	0,01	3	0,012	3	0,012	3	0,012	3	0,012	3	0,012
	25	test01_03	3	0,266	3	0,266	3	0,434	3	0,266	3	0,266	3	0,249	3	0,249	3	0,249
5	75	test01_04	5	0,001	5	0,001	5	0,004	5	0,001	5	0,001	5	0,004	5	0,004	5	0,004
	50	test01_05	5	0,022	5	0,022	5	0,119	5	0,022	5	0,022	5	0,071	5	0,076	5	0,076
	25	test01_06	5	0,462	5	0,462	5	2,628	5	0,462	5	0,462	5	1,517	5	1,529	5	1,529
10	75	test01_07	10	0,003	10	0,003	10	0,014	8	0,996	10	0,003	10	0,003	10	0,003	10	0,003
	50	test01_08	10	0,045	10	0,045	10	0,314	9	0,042	10	0,045	10	0,045	10	0,183	10	0,183
	30	test01_09	10	0,494	10	0,494	7	10,912	8	1,353	10	0,494	10	0,494	10	1,445	10	1,448
15	75	test01_10	15	0,003	15	0,003	15	0,013	15	0,003	15	0,003	15	0,003	15	0,005	15	0,005
	50	test01_11	15	0,05	15	0,05	15	1,081	14	0,38	15	0,05	15	0,05	15	0,414	15	0,414
	35	test01_12	15	0,306	15	0,306	11	12,19	14	0,615	15	0,306	15	0,306	12	6,886	12	6,886



Obr. 62 – Grafické znázornění závislosti průměrné odchylky spektrálních úhlů na SNR pro $n=3$ a $n=15$ (Pure pixel algoritmy a NMF-QMV-b dosahují shodných hodnot, a proto se jejich průběhy překrývají. Také se překrývají průběhy algoritmů NMF-QMV-c a NMF-QMV-t)


Testovací snímky pro první test byly sestaveny z náhodně vybraných materiálů ze spektrální knihovny `e_database_480_pruned_3`. Avšak bylo dodrženo pravidlo, aby v rámci jediného testu byly snímky se stejným počtem endmembers sestaveny ze shodných materiálů (např. pro $n=3$: snímku `test01_01` byly náhodně vybrané materiály s indexy 123, 448 a 452, tyto indexy byly následně využity při generování navazujících snímků `test01_02` a `test01_03`).

Z výsledků tohoto testu je patrné, že zvětšující se počet materiálů tvořících jeden snímek i snižující se hodnota SNR mají významný vliv na přesnost algoritmů hyperspektrálního rozkladu při odhadu průběhů endmembers.

V případě sady snímků s pure pixels dosahují nejlepších výsledků pure pixels algoritmy s výjimkou algoritmu PPI (s nastaveným parametrem `num_skewers = 1000`), který nedokázal správně odhadnout 1 či 2 materiály pro snímky skládající se z 10 či 15 materiálů. Algoritmy VCA, N-FINDR a AVMAX dokázaly správně odhadnout všechny obsažené materiály a dosáhly minimálních průměrných odchylek spektrálního úhlu.

Tabulka 9: Shrnující test na snímcích bez pure pixels

Test_HU_Algs_02																		
n	SNR	Název	VCA		N-FINDR		SISAL		PPI		AVMAX		NMF-QMV - b		NMF-QMV - c		NMF-QMV - t	
			est	mean	est	mean	est	mean	est	mean	est	mean	est	mean	est	mean	est	mean
3	75	test02_01	3	0,113	3	0,113	3	0,016	3	0,113	3	0,113	3	0,062	3	0,062	3	0,062
	50	test02_02	3	0,322	3	0,322	3	0,016	3	0,204	3	0,204	3	0,112	3	0,112	3	0,112
	25	test02_03	3	0,436	3	0,436	3	0,474	3	0,436	3	0,427	3	0,209	3	0,209	3	0,209
5	75	test02_04	5	1,131	5	1,131	5	0,016	4	1,312	5	1,131	5	0,245	5	0,251	5	0,251
	50	test02_05	5	0,937	5	0,992	5	0,052	4	1,217	5	0,992	5	0,105	5	0,105	5	0,105
	25	test02_06	5	1,217	4	1,378	5	1,717	2	3,178	4	1,378	5	0,64	5	0,628	5	0,628
10	75	test02_07	5	3,338	6	3,454	10	0,103	3	4,254	5	4,381	10	0,948	10	1,05	10	1,051
	50	test02_08	4	4,323	6	4,173	10	0,345	3	4,169	6	4,351	10	1,584	10	0,983	10	0,984
	30	test02_09	5	3,746	5	3,669	7	19,648	3	2,684	5	3,669	8	2,579	10	1,497	10	1,497
15	75	test02_10	4	3,486	4	2,824	15	0,118	3	1,993	4	3,391	14	1,794	14	1,767	14	1,771
	50	test02_11	2	3,562	1	3,322	15	1,072	1	2,418	1	2,883	13	2,698	15	1,356	15	1,355
	35	test02_12	2	4,332	2	4,666	12	5,902	2	4,206	1	2,81	8	3,408	12	2,778	12	2,777



Obr. 63 - Grafické znázornění závislosti průměrné odchylky spektrálních úhlů na SNR pro $n=3$ a $n=15$ (Druhý graf obsahuje pouze průběh algoritmů SISAL a varianty algoritmu NMF-QMV)

V druhém testu, sledujícím přesnost odhadů na sadě dat bez čistých pixelů, již neobstály (od 10 materiálů na snímek) žádné pure pixel algoritmy. Z této skupiny dopadl nejlépe algoritmus N-FINDR, který z 10 materiálů (při SNR 75 i 50) dokázal správně identifikovat 6 materiálů. Algoritmy z druhé kategorie (Minimum Volume) dosáhly mnohem lepších výsledků, avšak žádný nedokázal identifikovat materiály se 100% přesností.

8.1.1 Výpočetní čas

Všechny algoritmy byly testovány na shodném zařízení. V tabulce níže jsou zobrazeny vypočítané průměrné časy z prvního testu.

Tabulka 10: Průměrné výpočetní časy z prvního testování

Compute times [s]								
n	VCA	N-FINDR	SISAL	PPI	AVMAX	NMF-QMV - b	NMF-QMV - c	NMF-QMV - t
3	0,01	0,04	12,95	0,09	0,15	24,87	28,84	30,40
5	0,01	0,07	4,38	0,07	0,04	51,15	51,46	54,92
10	0,03	0,18	8,45	0,07	0,10	97,40	102,99	104,99
15	0,03	0,33	12,17	0,07	0,09	333,30	352,41	357,94

Pure pixel algoritmy dosahují velice nízkých hodnot průměrného výpočetního času (v řádu desetin či setin sekundy). V rámci prvního testu byl nejrychlejší algoritmus VCA s časem 0,004 s (při testování snímku test01_06).


Algoritmus SISAL dosahoval výpočetních časů v řadě jednotek či desítek sekund. Nejpomalejším z testovaných algoritmů byl NMF-QMV-t, který se vyhodnocoval téměř 6 minut v případě testování snímků složených z 15 materiálů.

8.1.2 Opakování pro shodná data

Při vyhodnocování hyperspektrálního rozkladu a určování matice míchání \mathbf{M} algoritmy různým způsobem využívají náhodně vygenerovaná data (PPI - skewers, N-FINDR a AVMAX - kombinace p spektrálních vektorů náhodně vybraných ze vstupního snímku, aj.).

Pro generování náhodných čísel je v Matlabu využit generátor pseudonáhodných čísel. Aby nedocházelo ke generování stále stejných „náhodných čísel“ tak byl do skriptu před algoritmy HU přidán příkaz pro zamíchání generátoru podle aktuálního času: `rng('shuffle')`.

Ve třetím testu bylo sledováno, jakým způsobem se budou měnit hodnoty průměrné odchylky spektrálního úhlu při opakovaném vyhodnocování na shodném vstupním snímku. Jako testovací snímek byl zvolen: test02_04. Vybraný testovací snímek se skládá z 5 materiálů, hodnota SNR je 75 dB, neobsahuje pure pixels a jeho součástí je 5 outliers. Na obrázku níže jsou zobrazeny rozdíly v přesnosti odhadu endmembers jednotlivých algoritmů pro 6 opakování na tomto snímku.



Obr. 64 - Opakování algoritmů HU pro shodný vstupní snímek

Při prvním testování tohoto snímku (viz tabulka 9) dokázaly všechny algoritmy, kromě PPI, správně určit všech 5 materiálů (PPI pouze 4). Správnost odhadu dokázaly tyto algoritmy zopakovat i při následujících 5 opakováních. Algoritmus PPI dokázal z celkových 6 pokusů třikrát správně určit všechny materiály a třikrát pouze 4 materiály z 5.

Z grafu na obrázku 64 plyne, že pure pixel algoritmy jsou více ovlivněny (na non pure pixel snímku) generátorem náhodných čísel, který využívají v průběhu odhadu endmembers. Na testovaném snímku tyto algoritmy dosahovaly rozdílů v řádu desetiny stupně průměrné odchylky spektrálního úhlu. MV algoritmy dosahovaly v testu mnohem stabilnějších výsledků, v případě všech variant algoritmu NMF-QMV byla odchylka spektrálního úhlu pokaždé shodná.

8.1.3 SNR

V této části byl testován vliv šumu na odhad endmembers. Pro účely tohoto testu byly vytvořené 3 sady HSI dat, na jejichž testování byla sledována změna přesnosti odhadů jednotlivých algoritmů v závislosti na parametru SNR.

První sada obsahuje data se stejnými parametry jako mají non-pure pixel snímky z druhého testu (x, y, λ : $100 \times 100 \times 480$, endmembers: 5, pure pixel: no, outliers: 5, knihovna: pruned_3), akorát bylo náhodně vybráno jiných 5 materiálů, které se následně použily pro syntézu všech snímků v této sadě, resp. pro celé testování vlivu SNR. Snímky z druhé sady již neobsahují outliers a ve třetí sadě byly využity pouze snímky s pure pixels.

Na následující stránce je ukázka tabulky s výsledky porovnání (ukázka hodnot pro algoritmy N-FINDR a VCA) a z ní vyvozené grafy pro všechny testované algoritmy.

V případě pure pixel snímků dokázaly všechny algoritmy správně odhadnout všech pět materiálů, pouze s výjimkou algoritmu SISAL při nejnižším odstupě signálu od šumu (SNR = 12 dB, 4 materiály). Na pravé straně obrázku 66 je zobrazený odpovídající graf. Z grafu je patrná pravidelnost, kde s klesající hodnotou SNR roste pro všechny algoritmy odchylka spektrálního úhlu. Nejnižších odchylek dosahují pure pixel algoritmy, křivky MV algoritmů mají větší strmost. Křivka algoritmu SISAL se láme přibližně okolo hodnoty 25 dB, zatímco algoritmy NMF-QMV až při cca o 5 dB nižším SNR.

Pro non-pure pixel data již algoritmus PPI přestává podávat vhodné výsledky (správné určené 3 nebo 4 materiály z pěti). Ostatní algoritmy při této zkoušce obstály, opět s výjimkou algoritmu SISAL při SNR 12 dB (4 materiály). Křivky závislosti průměrných odchylek na odstupě signálu od šumu jsou zobrazeny na obrázku 66 vlevo. Pure pixel algoritmy dosahují nepravidelných výsledků s průměrnými odchylkami pohybujícími se okolo 2° – 3° . Pro vysoké hodnoty SNR dosahuje nejlepších výsledků algoritmus SISAL (do SNR 40 dB odchylky pod $0,2^\circ$), avšak se zvětšujícím se vlivem šumu nastává výrazný nárůst odchylky.


Přidáním outliers se začala objevovat chybovost u algoritmu VCA (viz tabulka 11) a v menší míře i u algoritmu AVMAX (viz obrázek 67: snímek test03_13). Křivky pure pixel algoritmů (viz obr. 65) zůstaly nadále nepravidelné s hodnotami průměrných odchylek okolo 3° . Pro třetí sadu snímků dokázaly MV algoritmy správně určit všechny materiály (včetně algoritmu SISAL na 12 dB). Jejich křivky mají podobný průběh jako v předchozí variantě.

Tabulka 11: Ukázka tabulek pro test vlivu šumu na algoritmy HU


Algoritmus:		Non pure pixel HSI & outliers							
Název	SNR	VCA				N-FINDER			
		est	min	max	mean	est	min	max	mean
test03_01	100	5	0,771	4,876	2,71	5	1,03	4,864	2,528
test03_02	95	5	0,583	4,403	2,621	5	0,583	3,455	2,282
test03_03	90	4	2,115	9,923	5,022	5	1,027	4,881	2,921
test03_04	85	5	0,629	3,628	2,626	5	0,629	3,628	2,503
test03_05	80	5	0,891	3,893	2,104	5	0,901	3,893	2,106
test03_06	75	4	1,453	12,113	4,86	5	1,453	4,882	2,595
test03_07	70	4	0,751	3,535	2,233	5	0,727	5,048	2,792
test03_08	65	5	1,24	7,538	4,448	5	1,24	4,81	2,854
test03_09	60	5	1,314	5,551	3,499	5	1,314	4,262	2,656
test03_10	55	5	1,871	14,103	5,498	5	1,148	5,096	3,025
test03_11	50	5	0,938	5,583	2,869	5	0,938	5,583	2,719
test03_12	45	5	1,626	5,585	3,538	5	1,498	5,261	3,208
test03_13	40	4	1,899	3,42	2,611	5	1,369	3,42	2,292
test03_14	35	5	2,713	6,252	3,947	5	1,979	3,407	2,887
test03_15	30	5	0,605	6,143	3,277	5	0,605	5,002	2,898
test03_16	25	5	2,005	3,091	2,518	5	1,176	3,091	2,352
test03_17	20	5	2,491	4,302	3,227	5	2,491	4,373	3,091
test03_18	15	5	2,347	4,036	3,135	5	1,219	4,036	2,664
test03_19	12	4	1,481	5,041	3,33	5	1,3	5,444	3,005

Algoritmus:		Non-pure pixel HSI							
Název	SNR	VCA				N-FINDER			
		est	min	max	mean	est	min	max	mean
test05_01	50	5	1,395	3,956	2,263	5	1,395	3,956	2,263
test05_02	40	5	1,346	4,318	2,473	5	1,346	4,318	2,473
test05_03	30	5	0,45	3,185	2,076	5	0,45	3,185	1,857
test05_04	25	5	2,06	4,437	3,031	5	2,06	3,84	2,912
test05_05	20	5	1,984	4,496	3,062	5	2,084	4,405	3,093
test05_06	15	5	1,556	4,563	2,979	5	1,556	4,066	2,643
test05_07	12	5	3,482	6,693	5,124	5	1,058	5,023	3,125

Algoritmus:		Pure pixel HSI							
Název	SNR	VCA				N-FINDER			
		est	min	max	mean	est	min	max	mean
test06_01	50	5	0,013	0,028	0,019	5	0,013	0,028	0,019
test06_02	40	5	0,042	0,106	0,06	5	0,042	0,106	0,06
test06_03	30	5	0,081	0,326	0,162	5	0,081	0,326	0,162
test06_04	25	5	0,188	0,601	0,313	5	0,188	0,601	0,313
test06_05	20	5	0,261	0,727	0,457	5	0,261	0,727	0,457
test06_06	15	5	0,657	1,364	0,986	5	0,657	1,364	0,986
test06_07	12	5	0,821	2,176	1,372	5	0,821	2,176	1,372

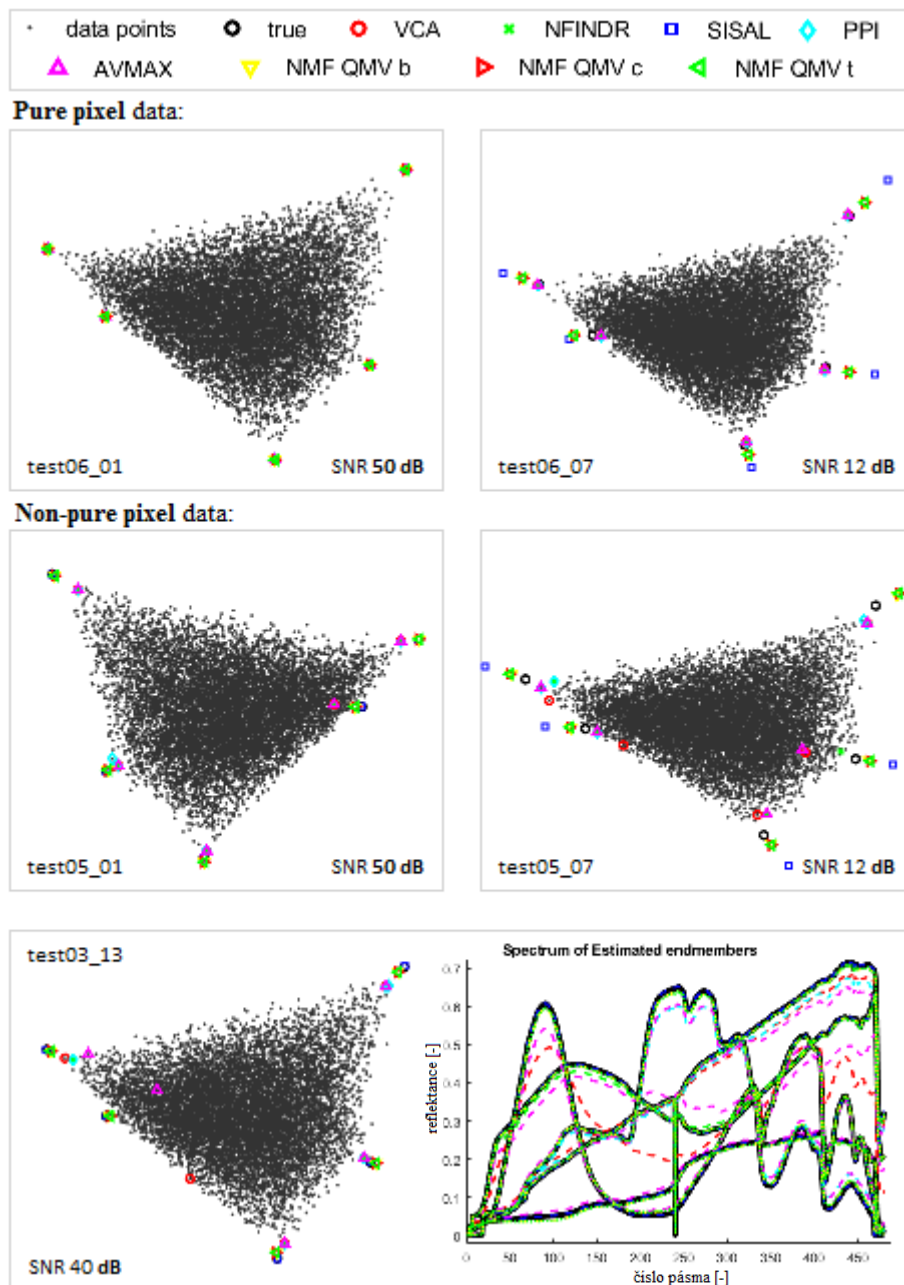


Obr. 65 - Vliv SNR na přesnost odhadu algoritmů HU, pro non-pure pixel snímky, včetně outliers



Obr. 66 – Vliv SNR, vlevo: 2. sada (non-pure pixels), vpravo: 3. sada (pure pixels)


Ze čtvrtého testu vychází N-FINDR jako pure pixel algoritmus s největší odolností proti šumu. Avšak v případě dat bez pure pixelů dosahuje tato skupina algoritmů výrazně horších výsledků oproti MV algoritmům. Z této skupiny dosáhl nejnižších odchylek algoritmus SISAL, ale pouze pro vysoká SNR. Z toho důvodu z testovaných algoritmů vychází jako nejvíce odolné proti šumu všechny varianty algoritmu NMF-QMV, které dosahují vůči sobě pouze nepatrných rozdílů.



Obr. 67 – Ukázka 2D projekcí odhadnutých endmembers podle jednotlivých algoritmů (figures 04). Na posledním obrázku jsou viditelné 2 nepřesně odhadnuté endmembery (VCA a AVMAX) a jejich spektrální průběhy (Figure 05)

8.1.4 Počet endmembers

V posledním testu byl sledován vliv počtu endmembers na přesnost jejich odhadu. Algoritmy HU byly opět testovány na dvou sadách snímků, jedna obsahující snímky s pure pixels, druhá nikoliv (všechny snímky byly generovány z knihovny pruned_5 a s hodnotou SNR 50 dB).



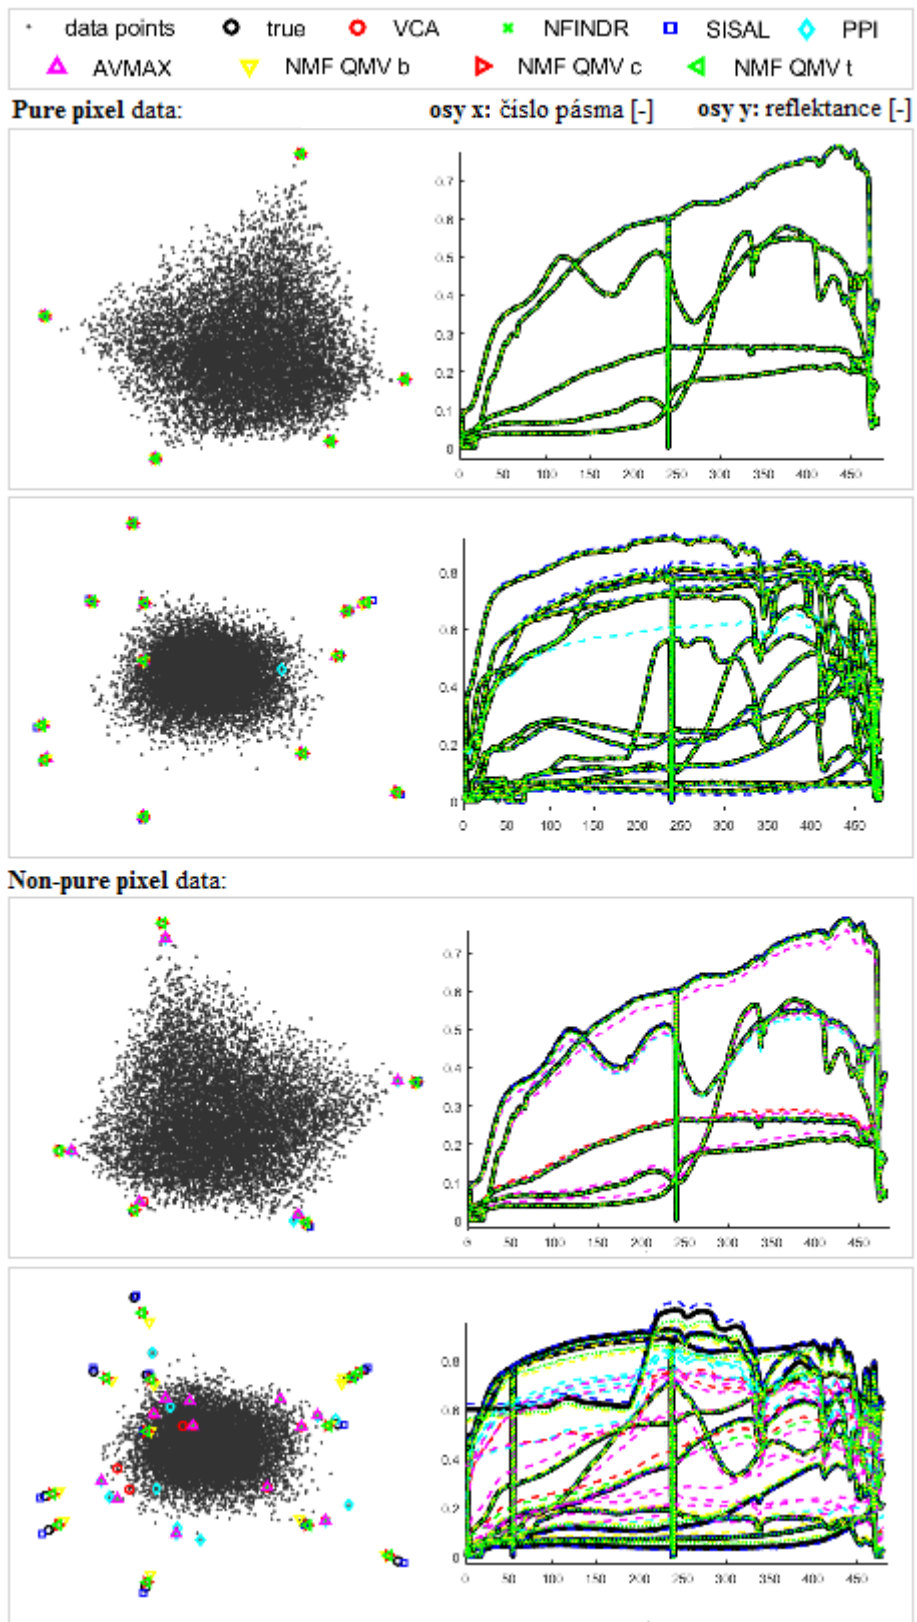
Obr. 68 – Závislost průměrných odchylek spektrálních úhlů na počtu endmembers, vlevo: pure pixel data, vpravo: non-pure pixel

Výsledky z první sady ukazují, že v případě kdy snímky obsahují pure pixels, tak všechny algoritmy dokáží správně odhadnout jednotlivé materiály pouze s malými odchylkami (pure pixel algoritmy a NMF-QMV-b dosáhly téměř nulových odchylek, zbylé dvě varianty algoritmu NMF-QMV měly největší průměrnou odchylku okolo 0,3° a algoritmus SISAL okolo 1,2°). Jediný algoritmus, u kterého byly zaznamenány chyby je PPI (pro n = 12 bylo určeno jen 11 materiálů a pro n = 15 správně odhadnuto 13 materiálů).

Tabulka 12: Vliv počtu endmembers na algoritmy HU, non-pure pixel data

Algoritmus:		VCA		N-FINDR		SISAL		PPI		AVMAX		NMF-QMV - b		NMF-QMV - c		NMF-QMV - t	
Název	n	est	mean	est	mean	est	mean	est	mean	est	mean	est	mean	est	mean	est	mean
test07_07	3	3	0,479	3	0,479	3	0,015	3	0,479	3	0,479	3	0,252	3	0,252	3	0,252
test07_08	5	5	1,676	5	1,599	5	0,048	4	1,681	5	1,599	5	0,144	5	0,144	5	0,144
test07_09	7	4	5,136	5	4,046	7	0,126	4	4,545	5	4,046	7	0,726	7	0,636	7	0,638
test07_10	10	5	3,923	5	4,107	10	0,812	5	3,159	6	4,169	10	2,383	10	1,454	10	1,457
test07_11	12	5	5,491	5	4,15	12	1,261	3	6,193	5	4,15	9	3,547	12	2,112	12	2,114
test07_12	15	4	4,622	5	4,985	15	0,781	4	3,636	4	4,55	12	2,299	11	2,948	11	2,947

Vyhodnocení druhé sady snímků, která již neobsahuje pure pixels, ukazuje na chybovost pure pixel algoritmů od počtu materiálů n = 7. Z MV algoritmů dosáhl nejhorších výsledků algoritmus NMF-QMV-b, u kterého došlo k špatnému odhadu materiálů pro n = 12 (správně určeno 9) a n = 15 (správně určeno 12). Zbylé dvě varianty algoritmu NMF-QMV dosáhly špatných výsledků až při n = 15 (oba správně určily 11 materiálů). Algoritmus SISAL určil správně všechny materiály a zároveň dosahoval nejmenších průměrných odchylek spektrálního úhlu (viz obrázek 68 vpravo).



Obr. 69 – Ukázky výstupních Figures 04 a 05 pro test vlivu počtu endmembers (pro $n=5$ a $n=12$)

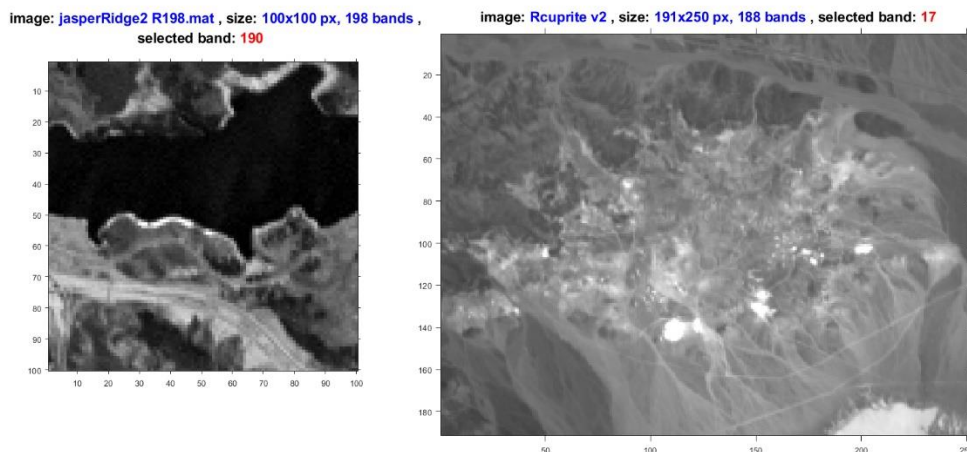
8.2 Reálná data

Z testování na syntetických datech je patrné, že účinnost algoritmů hyperspektrálního rozkladu závisí na všech testovaných parametrech (počet materiálů, SNR, přítomnost pure pixelů).

Snímky pořízené hyperspektrálními kamerami jsou v oblasti vzdáleného snímání pořizovány z vysokých nadmořských výšek na senzor s omezeným prostorovým rozlišením. Z toho důvodu je, vzhledem k jevu spektrálního míchání, u těchto snímků vysoce nepravděpodobná přítomnost pure pixelů. Také lze předpokládat, že přes všechny aplikované korekce (viz preprocessing) bude výsledný snímek zatížený nepřesnostmi. Dokonce u některých snímků je nutné odstranit vybraná spektrální pásma kvůli vlivu šumu a absorpčních pásem v atmosféře. Všechny tyto jevy mají vliv na kvalitu výstupního snímku, tím pádem je zapotřebí odolných a účinných algoritmů.

Metody z oblasti geometrického hyperspektrálního rozkladu teoreticky poskytují řešení inverzního problému aplikováním algoritmů na zaznamenaný hyperspektrální snímek bez znalosti dalších informací. V případě syntetických dat byl na vstupu pouze HSI snímek, aplikací algoritmu Hysime se odhadl počet obsažených materiálů, jejichž průběhy se následně určily pomocí algoritmů HU. Při analýze reálných dat je obtížné pro automatický algoritmus Hysime správně určit počet materiálů. Z toho důvodu byly pro účely této práce vybrané snímky, u kterých je předem známý počet obsažených materiálů. Zároveň byl požadavek na znalost přibližných průběhů těchto materiálů, aby bylo možné porovnat výstupy jednotlivých algoritmů. Zde také nastává otázka definování těchto materiálů, resp. jaké materiály mají být definované jako hlavní složky (endmembers) obsažené v daném snímku. Zatímco u některých často používaných HSI snímků jsou pro testování definované obecné materiály (vegetace, voda, půda, aj.) jako endmembers, tak u jiných snímků jsou jako referenční materiály uváděny přímo materiály z USGS spektrální knihovny. V této práci byl otestován jeden HSI snímek z každé této kategorie.

Vzhledem k pomalým výpočetním časům (obzvláště u všech variant algoritmu NMF-QMV) byly pro práci s reálnými snímky vybrány pouze malé výřezy snímků.




Obr. 70 – 2D náhledy vybraných HSI: vlevo Jasper Ridge a vpravo Cuprite

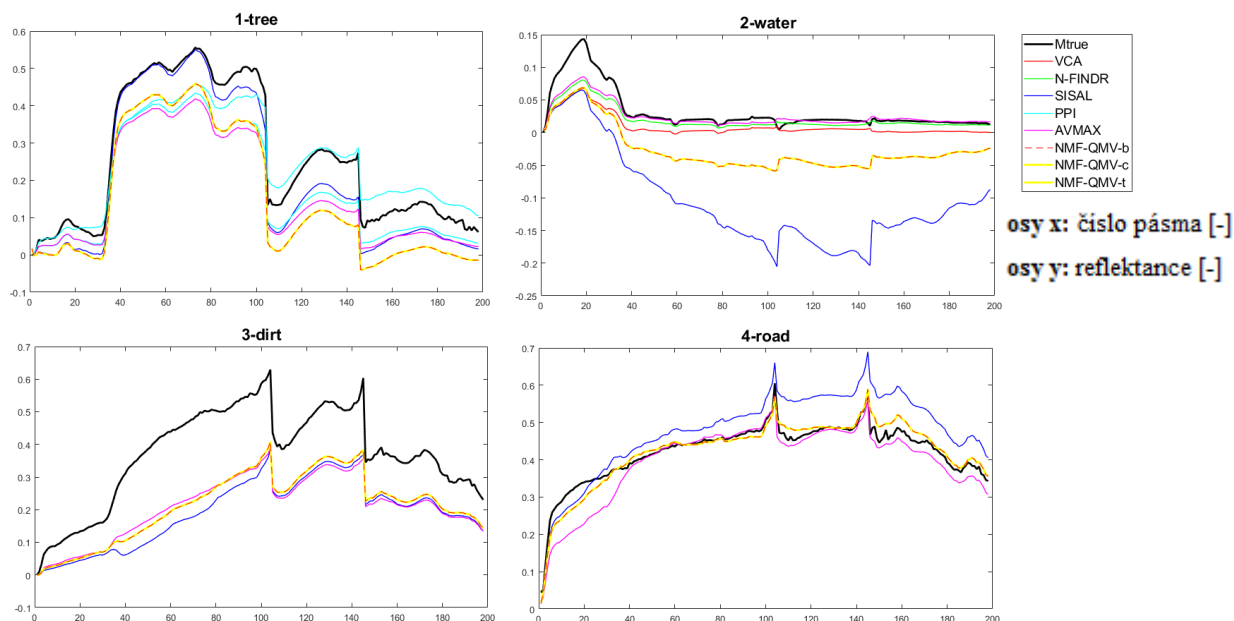
8.2.1 Jasper Ridge

Prvním vybraným snímkem je Jasper Ridge. Jedná se o 100×100 px velký výřez z původního snímku. Původní snímek byl pořízený na 224 spektrálních pásmech v rozsahu vlnových délek 380–2500 nm. Po odstranění nevhodných pásem zůstává HSI snímek o rozměrech $100 \times 100 \times 198$ (x, y, λ). Na tomto snímku je zobrazena řeka a k ní přilehá země se silnicí. Součástí tohoto snímku v databázi je také matice obsahující spektra 4 materiálů, označených jako referenční, a také snímek Ground Truth s informací o jejich rozložení. Jako referenční materiály byly označeny: stromy, voda, půda a silnice. [82]

Automatický algoritmus Hysime určil velikost dimenze uvažovaného podprostoru jako $p = 18$. Vzhledem k počtu referenčních materiálů byla dimenze manuálně nastavena na hodnotu 4. Výsledky odhadu spektrálních průběhů materiálů jsou zobrazeny na obrázku 72. Rozložení spektrálních vektorů na 3D bodovém grafu je součástí přílohy na CD. Všechny algoritmy, kromě algoritmu PPI, dokázaly úspěšně odhadnout přibližný tvar spekter jednotlivých referenčních materiálů. Algoritmus PPI správně odhadl průběh 4. materiálu, avšak místo 2. a 3. materiálu určil třikrát průběh prvního spektra.



Obr. 71 - Procentuální rozložení odhadnutých materiálů na snímku Jasper Ridge podle algoritmu NMF-QMV



Obr. 72 - Porovnání spekter odhadnutých a referenčních materiálů snímku Jasper Ridge

Pro jednotlivé algoritmy byly určeny odchylky spektrálních úhlů odhadnutých endmembers oproti referenčním spektrům (viz tabulka 13). Algoritmy nejlépe určily spektrum 4. materiálu (prům. odchylka 4,18°), naopak nejhůře byl určen druhý materiál (prům. odchylka 56°). Z číselných hodnot v tabulce 13 vychází překvapivě lépe, vzhledem k předcházejícím testům na syntetických datech, pure pixel algoritmy (mimo algoritmus PPI).

Algoritmy NMF-QMV umožňují také realizaci navazujícího kroku hyperspektrálního rozkladu, tedy sestavení snímků abundances. Ukázka jejich zobrazení viz obrázek 71.

Tabulka 13: Jasper Ridge, odchylky spektrálních úhlů [°]

	Tree 1	Water 2	Dirt 3	Road 4	Průměr
VCA	8,49	14,63	6,68	5,17	8,74
N-FINDR	8,49	6,35	6,68	5,17	6,67
SISAL	10,00	104,28	14,17	4,16	33,15
PPI	6,13	-	-	5,17	-
AVMAX	8,49	11,53	6,68	5,17	7,97
NMF-QMV-b	16,31	85,24	9,87	2,87	28,57
NMF-QMV-c	16,31	85,24	9,87	2,87	28,57
NMF-QMV-t	16,31	85,24	9,87	2,87	28,57
Průměr	11,31	56,07	9,12	4,18	

PPI	6,13	8,79	8,49	Pro první materiál
-----	------	------	------	--------------------

	Nejnižší hodnota pro daný endmember
	Výrazně vysoké hodnoty

8.2.2 Cuprite

Hyperespektrální snímek Cuprite byl pořízený systémem AVIRIS nad stejnojmenným pohořím (Cuprite Hills) ve statě Nevada, USA. Parametry tohoto snímku jsou po nezbytných úpravách následující: $191 \times 250 \times 188$ (x, y, λ), spektrální rozsah: 370–2480 nm. Podle ground truth informace se na zaznamenané ploše nachází 12 materiálů, jejichž referenční spektra byla vybrána z USGS spektrální knihovny a upravena tak, aby odpovídala vlastnostem použitého systému a zaznamenaného snímku (spektrální rozsah a odebrané hodnoty odpovídající rozsahům vlnových délek absorpčních pásem). [82]

Tabulka 14: Seznam obsažených materiálů, podle zdrojů [58] a [82]

#	Material	Celý název .asc souboru	#	Material	Celý název .asc souboru
1	Alunite	Alunite_gds82.1063	7	Muscovite	Muscovite_il107.15566
2	Andradite_1	Andradite_ws487.2330	8	Montmorillonite	Montmorillonite+Illite CM37
3	Buddingtonite	Buddingtonite_gds85.3924	9	Nontronite	Nontronite NG-1.a
4	Dumortierite	Dumortierite_hs190.7191	10	Andradite_2	Andradite WS474
5	Kaolinite_1	Kaolin_Smect H89-FR-5 .3Kaol	11	Sphene	Sphene HS189.3B
6	Kaolinite_2	Kaolin_Smect KLF508 .85Kaol	12	Chalcedony	Chalcedony_cu91-6a.4502

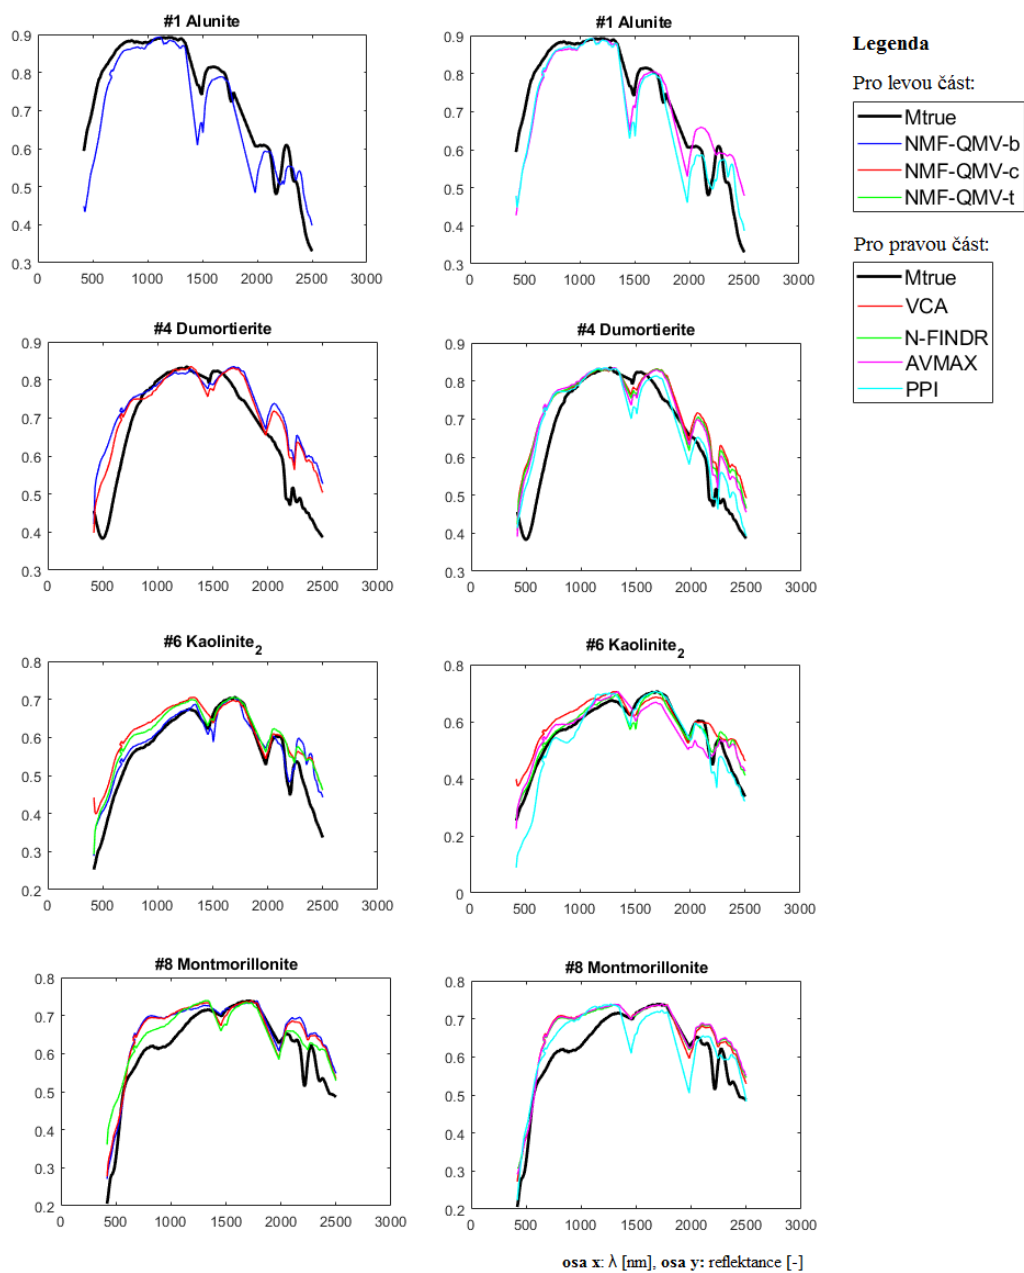
Tabulka 15: Velikosti spektrálních úhlů mezi endmembry a odpovídajícími materiály

		X/12	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12	mean
VCA	M1	8	4,90	-	-	4,27	5,11	3,60	-	3,45	3,97	3,48	-	4,08	4,11
N-FINDR	M2	8	4,90	-	-	4,40	4,82	3,95	-	3,40	4,32	4,46	-	4,64	4,36
SISAL	M3	2	52,61	-	-	-	-	-	-	3,55	-	-	-	-	28,08
PPI	M6	6	4,90	-	-	5,56	4,82	5,52	-	4,50	-	-	-	3,64	4,83
AVMAX	M7	7	6,01	-	-	4,59	-	4,57	-	3,45	3,97	-	3,69	4,76	4,43
NMF-QMV B	M8	9	5,78	4,69	-	4,41	5,04	4,72	-	3,54	4,98	-	20,66	5,52	6,59
NMF-QMV C	M9	7	-	3,87	-	4,18	4,96	2,89	-	3,42	-	5,34	3,62	-	4,04
NMF-QMV T	M10	4	-	4,28	-	-	-	2,84	-	2,97	-	3,71	-	-	3,45

V testu na snímku Cuprite byly nejprve odhadnuty matice míchání pro všechny algoritmy (**M1** až **M10**). Následně byly porovnány průběhy odhadnutých endmembers ($\mathbf{U}_p \times \mathbf{M}_x$) se všemi spektry referenčních materiálů (**Mref**). Pro každý endmember byl výstupem index materiálu s nejmenším vzájemným spektrálním úhlem a jeho hodnota. Výsledky tohoto testu jsou zobrazeny v tabulce 15. Ve výsledcích docházelo k opakovaným odhadům shodného materiálu pro více endmemberů. V takovém případě byla vybrána hodnota s menším spektrálním úhlem. Z toho důvodu některé materiály nebyly vůbec určeny.

Žádný z testovaných algoritmů nedokázal rozlišit všech 12 referenčních materiálů. Nejvíce materiálů určil algoritmus NMF-QMV-b (9 materiálů), nejméně algoritmus SISAL (2 materiály), který při porovnávání s referenčními materiály (**Mref**) určil 11 endmemberů s

nejmenším spektrálním úhlem se shodným materiálem (#8). Průměrná odchylka spektrálních úhlů (pouze ze spektrálních úhlů vypsanych v tabulce 15, tzn. bez opakování odhadů pro shodný materiál) vychází podobně pro všechny pure pixel algoritmy (4-5°). Do tohoto rozsahu odchylek by patřil i algoritmus NMF-QMV-b, kdyby nebyla brána v potaz jeho spektrální odchylka od materiálu #11. Zbylé Algoritmy NMF-QMV dosahují nižších hodnot průměrných odchylek, ale na úkor méně rozpoznanych materiálů.



Obr. 73 – Ukázky porovnání spekter odhadnutých a referenčních materiálů snímku Cuprite

9 Závěr

Hyperspektrální snímání má vysoké nároky na technologii hyperspektrálních kamer i na metody analýzy pro zpracování zaznamenaných dat. Hyperspektrální rozklad a metody umožňující odhad hlavních složek patří do oblasti, která je stále ve fázi aktivního výzkumu.

V této práci byly popsány a otestovány metody geometrického hyperspektrálního rozkladu, konkrétně dvě skupiny algoritmů z této kategorie: Pure pixel a Minimum Volume. Z pure pixel algoritmů byl otestován jeden z prvních vytvořených algoritmů PPI, dva často používané algoritmy VCA a N-FINDR, a také algoritmus AVMAX, který vychází ze shodného principu jako N-FINDR. Ze druhé skupiny byl vybrán algoritmus SISAL a také NMF-QMV ucelený framework obsahující tři varianty známých přístupů k řešení optimalizace a volby regularizačního parametru, který je v rámci tohoto frameworku volen zcela automaticky.

Pro možnosti testování byla sestavena databáze hyperspektrálních snímků obsahující reálné snímky i prostředky na umělé vytvoření snímků s definovanými parametry. Také byl sestaven ucelený skript a několik funkcí, na jejichž základě byly provedeny testy na porovnání základních vlastností vybraných algoritmů.

Z testů dopadl nejhůře algoritmus PPI, který kromě nejmenší přesnosti při odhadování endmembers, také vykázal nestabilitu výsledků při opakování na shodných datech.

Algoritmy VCA, N-FINDR a AVMAX vykazovaly velice podobné, občas dokonce úplně shodné výsledky. U testů na syntetických datech obsahující pure pixely tyto algoritmy úspěšně odhadly všechny materiály. V případě non-pure pixel dat rostla chybovost s přibývajícím počtem materiálů.

Algoritmus SISAL prokazoval při testech na non-pure pixel syntetických datech nejlepší výsledky vzhledem k přesnosti odhadu endmembers, avšak z výsledků je patrná menší odolnost proti šumu. Ta je patrná i u testu na reálných snímcích. Algoritmus SISAL vyžaduje v závislosti na vstupním snímku ruční nastavení hodnoty regularizačního parametru. V rámci této práce byl tento parametr nastavený pevně po celou dobu testování.

Všechny varianty algoritmu NMF-QMV vykazovaly jednoznačně nejpomalejší výpočetní časy. To je způsobené opakováním skriptu při automatické volbě regularizačního parametru. Avšak v rámci této práce byla prokázána důležitost tohoto parametru a zároveň užitečnost možnosti jeho automatické volby.

10 Seznam použité literatury

- [1] VRBOVÁ, Miroslava, Helena JELÍNKOVÁ a Petr GAVRILOV. Úvod do laserové techniky. Dot. 1. vyd. Praha: ČVUT, 1998. ISBN 80-01-01108-9.
- [2] FIALA, Pavel a Ivan RICHTER. Fyzikální optika. Vyd. 2., přeprac. Praha: Vydavatelství ČVUT, 2005. ISBN 80-01-03183-7.
- [3] Elektromagnetické spektrum a viditelné světlo. Labguide.cz [online]. [cit. 2019-06-27]. Dostupné z: <https://labguide.cz/fluorochromy/>
- [4] Disperze. Fyzika.jreichl.com [online]. [cit. 2019-06-27]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/441-disperze-rozklad-svetla>
- [5] Využití disperze. Fyzika.jreichl.com [online]. [cit. 2019-06-27]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/443-vyuziti-disperze-svetla>
- [6] Optické hranoly. Fyzika.jreichl.com [online]. [cit. 2019-06-27]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/442-opticke-hranoly>
- [7] Optický hranol. www.moty.cz [online]. [cit. 2019-06-27]. Dostupné z: <https://www.moty.cz/advisor/hranoly-v-binokularnich-dalekohledech-recenze-radce>
- [8] Huygensův princip. Fyzika.jreichl.com [online]. [cit. 2019-06-27]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/170-vlneni-v-izotropnim-prostredi>
- [9] Peatross, J., & Ware, M. Physics of light and optics. Provo, UT: Brigham Young University, Department of Physics, 2015. ISBN 978-1-312-92927-2.
- [10] Ohyb světla na hraně. Fyzika.jreichl.com [online]. [cit. 2019-06-27]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/560-ohyb-svetla-na-hrane>
- [11] Difrakční mřížky. Thorlabs.com [online]. [cit. 2019-06-27]. Dostupné z: https://www.thorlabs.com/navigation.cfm?guide_id=9
- [12] Ohyb světla na mřížce. Fyzika.jreichl.com [online]. [cit. 2019-06-27]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/461-ohyb-svetla-na-mrizce>
- [13] Ohyb světla na dvou štěrbinách. Fyzika.jreichl.com [online]. [cit. 2019-06-27]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/460-ohyb-svetla-na-dvou-sterbinach>
- [14] Difrakční mřížky (Gratings tutorial). Thorlabs.com [online]. [cit. 2019-06-27]. Dostupné z: https://www.thorlabs.com/newgrouppage9.cfm?objectgroup_id=1122

- [15] Li, Q., He, X., Wang, Y., Liu, H., Xu, D., & Guo, F. (2013). Review of spectral imaging technology in biomedical engineering: Achievements and challenges. *Journal of Biomedical Optics*, 18(10), 100901. doi:10.1117/1.jbo.18.10.100901
- [16] HSI. Specim.fi [online]. [cit. 2019-06-27].
Dostupné z: <http://www.specim.fi/what-hyperspectral-imaging-provides/>
- [17] PIHAN, Roman. *Mistrovství práce s DSLR, vydání deváté*. Praha: IDIF, 2014. ISBN 978-80-905601-3-0.
- [18] Optická část fotoaparátů. global.canon [online]. [cit. 2019-06-27].
Dostupné z: <https://global.canon/en/imaging/dlo/effect/index.html>
- [19] Spektrometrie. admesy.com [online]. [cit. 2019-06-27].
Dostupné z: <https://www.admesy.com/application/general-spectrometry/>
- [20] HSI. Specim.fi [online]. [cit. 2019-06-27].
Dostupné z: <http://www.specim.fi/what-is-hyperspectral-imaging/>
- [21] Smith, R.B. (2012), *Introduction to hyperspectral imaging with TMIPS, MicroImages*
Dostupné z: <https://www.microimages.com/documentation/Tutorials/hyprspec.pdf>
- [22] Princip spektrometru. bwtek.com [online]. [cit. 2019-06-27].
Dostupné z: <http://bwtek.com/spectrometer-introduction/>
- [23] Princip a parametry spektrometrů. optixs.cz [online]. [cit. 2019-06-27].
Dostupné z: <http://www.optixs.cz/spektrometry-29k/vlaknove-spektrometry-55k/ocean-fx-vlaknovy-spektrometr-110p>
- [24] Technologie spektroskopie. fourierphotonics.com [online]. [cit. 2019-06-27].
Dostupné z: <http://www.fourierphotonics.com/en/technology/>
- [25] Konfigurace spektrometrů. horiba.com [online]. [cit. 2019-06-27].
Dostupné z: https://www.horiba.com/en_en/technology/measurement-and-control-techniques/optical-spectroscopy/monochromator-and-spectrometers/monochromator-spectrometer/
- [26] Kim, S. H., Kong, H. J., Lee, J. U., Lee, J. H., & Lee, J. H. (2014). Design and construction of an Offner spectrometer based on geometrical analysis of ring fields. *Review of Scientific Instruments*, 85(8), 83108. <https://doi.org/10.1063/1.4892479>

- [27] NEUMANN, Wilfried. Fundamentals of dispersive optical spectroscopy systems. Bellingham, Washington USA: SPIE Press, [2014]. ISBN isbn9780819498243.
- [28] Princip spektrometru. admesy.com [online]. [cit. 2019-06-27].
Dostupné z: <https://www.admesy.com/how-does-a-spectrometer-work/>
- [29] Konstrukce spektrometru. bwtek.com [online]. [cit. 2019-06-27].
Dostupné z: <http://bwtek.com/spectrometer-part-4-the-optical-bench/>
- [30] Konstrukce spektrometru. bwtek.com [online]. [cit. 2019-06-27].
Dostupné z: <http://bwtek.com/products/exemplar-plus-ls/>
- [31] Nathan A. Hagen, Michael W. Kudenov, "Review of snapshot spectral imaging technologies," Opt. Eng. 52(9) 090901 (23 September 2013) <https://doi.org/10.1117/1.OE.52.9.090901>
- [32] KUBA, Petr. Televizní technika: studiové zpracování televizního signálu. Praha: BEN - technická literatura, 2000. ISBN 80-86056-88-0.
- [33] R. Shogenji, Y. Kitamura, K. Yamada, S. Miyatake, and J. Tanida, "Multispectral imaging using compact compound optics," Opt. Express 12, 1643-1655 (2004).
- [34] Multispektrální kamera (wheel). Pixelteq.com [online]. [cit. 2019-06-27].
Dostupné z: <https://pixelteq.com/spectrocam/>
- [35] Multispektrální kamera. Pixelteq.com [online]. [cit. 2019-06-27].
Dostupné z: <https://pixelteq.com/pixelcam/>
- [36] Terminologie hyperspektrálního zobrazování. Resonon.com [online]. [cit. 2019-06-27].
http://docs.resonon.com/spectronon/pika_manual/html/Glossary_include.html
- [37] Úvod do hyperspektrálního zobrazování. Resonon.com [online]. [cit. 2019-06-27].
Dostupné z: <https://resonon.com/content/files/Resonon-Hyperspectral-Tutorial-2.pdf>
- [38] Aplikace hyperspektrálního zobrazování v potravinářském průmyslu. Specim.fi [online]. [cit. 2019-06-27]. Dostupné z: <http://www.specim.fi/whats-really-in-your-meat/>
- [39] Aplikace hyperspektrálního zobrazování v potravinářském průmyslu. Specim.fi [online]. [cit. 2019-06-27]. Dostupné z: <http://www.specim.fi/food-fraud-detection-with-hyperspectral-imaging/>

- [40] Aplikace hyperspektrálního zobrazování v potravinářském průmyslu. Condifood.com [online]. [cit. 2019-06-27]. Dostupné z: <https://condifood.com/>
- [41] Průmyslové aplikace hyperspektrálního zobrazování. Specim.fi [online]. [cit. 2019-06-27]. Dostupné z: <http://www.specim.fi/bakedgoods/>
- [42] Aplikace hyperspektrálního zobrazování. Resonon.com [online]. [cit. 2019-06-27]. Dostupné z: <https://resonon.com/applications>
- [43] Aplikace hyperspektrálního zobrazování. Imec-int.com [online]. [cit. 2019-06-27]. Dostupné z: <https://www.imec-int.com/en/hyperspectral-imaging?slide=5>
- [44] Forezní aplikace hyperspektrálního zobrazování. Specim.fi [online]. [cit. 2019-06-27]. Dostupné z: <http://www.specim.fi/forensics-with-hyperspectral-imaging/>
- [45] Jignesh S. Bhatt, Manjunath V. Joshi. Regularization in Hyperspectral Unmixing: Bellingham, Washington (1000 20th St. Bellingham WA 98225-6705 USA) : SPIE, 2016.. ISBN: 9781510607606
- [46] Aplikace v precizním zemědělství. Gamaya.com [online]. [cit. 2019-06-27]. Dostupné z: <https://gamaya.com>
- [47] Aplikace v precizním zemědělství. Variabilni-aplikace.cz [online]. [cit. 2019-06-27]. Dostupné z: http://www.variabilni-aplikace.cz/presne_davkovani.php
- [48] Great Lakes Environmental Research. Glerl.noaa.gov [online]. [cit. 2019-06-27]. Dostupné z: https://www.glerl.noaa.gov/res/HABs_and_Hypoxia/airSatelliteMon.html
- [49] Hyperspektrální zobrazování. Bodkindesign.com [online]. [cit. 2019-06-27]. Dostupné z: <http://www.bodkindesign.com/products-page/hyperspectral-imaging/hyperspectral-imaging/>
- [50] J. M. Bioucas-Dias, A. Plaza, G. Camps-Valls, P. Scheunders, N. Nasrabadi and J. Chanussot, Hyperspectral Remote Sensing Data Analysis and Future Challenges: IEEE Geoscience and Remote Sensing Magazine, vol. 1, no. 2, pp. 6-36, June 2013.
doi: 10.1109/MGRS.2013.2244672
- [51] Hyperspektrální kamery. Specim.fi [online]. [cit. 2019-06-27]. Dostupné z: <http://www.specim.fi/hyperspectral-cameras/>

- [52] Snapschot hyperspektrální kamera. Imec-int.com [online]. [cit. 2019-06-27].
Dostupné z: <https://www.imec-int.com/drupal/sites/default/files/inline-files/XIMEA%20SNt32%20snapshot%20hyperspectral%20imaging%20camera.pdf>
- [53] Snapschot hyperspektrální kamera. Cubert-gmbh.com [online]. [cit. 2019-06-27].
Dostupné z: <https://cubert-gmbh.com/product/uhd-185-firefly/>
- [54] Linescan hyperspektrální kamera. Specim.fi [online]. [cit. 2019-06-27].
Dostupné z: <http://www.specim.fi/specim-fx50/>
- [55] Linescan hyperspektrální kamera. Resonon.com [online]. [cit. 2019-06-27].
Dostupné z: <https://resonon.com/pika-xc2>
- [56] Přehled hyperspektrálních kamer. Resonon.com [online]. [cit. 2019-06-27].
Dostupné z: <https://resonon.com/hyperspectral-cameras>
- [57] LEFEI ZHANG, LIANGPEI ZHANG, DACHENG TAO, XIN HUANG a BO DU. Hyperspectral Remote Sensing Image Subpixel Target Detection Based on Supervised Metric Learning. *IEEE Transactions on Geoscience and Remote Sensing* [online]. 2014, 52(8), 4955-4965 [cit. 2019-12-01]. DOI: 10.1109/TGRS.2013.2286195. ISSN 0196-2892. Dostupné z: <http://ieeexplore.ieee.org/document/6658949/>
- [58] RAJABI, Roozbeh a Hassan GHASSEMIAN. Sparsity Constrained Graph Regularized NMF for Spectral Unmixing of Hyperspectral Data. *Journal of the Indian Society of Remote Sensing* [online]. 2015, 43(2), 269-278 [cit. 2019-12-01]. DOI: 10.1007/s12524-014-0408-2. ISSN 0255-660X. Dostupné z: <http://link.springer.com/10.1007/s12524-014-0408-2>
- [59] ZHUANG, Lina, Chia-Hsiang LIN, Mario A. T. FIGUEIREDO a Jose M. BIOUCAS-DIAS. Regularization Parameter Selection in Minimum Volume Hyperspectral Unmixing. *IEEE Transactions on Geoscience and Remote Sensing* [online]. 2019, 57(12), 9858-9877 [cit. 2019-12-01]. DOI: 10.1109/TGRS.2019.2929776. ISSN 0196-2892. Dostupné z: <https://ieeexplore.ieee.org/document/8798985/>
- [60] BIOUCAS-DIAS, Jose M. a Antonio PLAZA. An overview on hyperspectral unmixing: Geometrical, statistical, and sparse regression based approaches. In: 2011 IEEE International Geoscience and Remote Sensing Symposium [online]. IEEE, 2011, 2011,

- s. 1135-1138 [cit. 2019-12-01]. DOI: 10.1109/IGARSS.2011.6049397. ISBN 978-1-4577-1003-2. Dostupné z: <http://ieeexplore.ieee.org/document/6049397/>
- [61] BIOUCAS-DIAS, José M., Antonio PLAZA, Nicolas DOBIGEON, Mario PARENTE, Qian DU, Paul GADER a Jocelyn CHANUSSOT. Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-Based Approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* [online]. 2012, 5(2), 354-379 [cit. 2019-12-01]. DOI: 10.1109/JSTARS.2012.2194696. ISSN 1939-1404. Dostupné z: <http://ieeexplore.ieee.org/document/6200362/>
- [62] J. Boardman, “Automating spectral unmixing of AVIRIS data using convex geometry concepts,” in *Proc. Ann. JPL Airborne Geosci. Workshop*, 1993, vol. 1, pp. 11–14.
- [63] Davidkun HyperSpectralToolbox. [github.com](https://github.com/davidkun/HyperSpectralToolbox) [online]. [cit. 2019-07-28].
Dostupné z: <https://github.com/davidkun/HyperSpectralToolbox>
- [64] Nascimento, José & Bioucas-Dias, Jose. (2005). Vertex component analysis: A fast algorithm to unmix hyperspectral data. *IEEE T. Geoscience and Remote Sensing*. 43. 898-910.
- [65] Zhou Q., Zhang J., Tian Q., Zhuo L., Geng W. (2016) Automatic Endmember Extraction Using Pixel Purity Index for Hyperspectral Imagery. In: Tian Q., Sebe N., Qi GJ., Huet B., Hong R., Liu X. (eds) *MultiMedia Modeling. MMM 2016. Lecture Notes in Computer Science*, vol 9517. Springer, Cham
- [66] Du, Qian & Raksuntorn, Nareenart & Younan, N.H. & King, Roger. (2008). Variants of N-FINDR algorithm for endmember extraction. *Proc. SPIE*. 7109. 10.1117/12.799361.
- [67] M. Zortea and A. Plaza, "A Quantitative and Comparative Analysis of Different Implementations of N-FINDR: A Fast Endmember Extraction Algorithm," in *IEEE Geoscience and Remote Sensing Letters*, vol. 6, no. 4, pp. 787-791, Oct. 2009.
- [68] Chan, Tsung-Han & Ma, Wing-Kin & Ambikapathi, Arulmurugan & Chi, Chong-Yung. (2011). A Simplex Volume Maximization Framework for Hyperspectral Endmember Extraction. *Geoscience and Remote Sensing, IEEE Transactions on*. 49. 4177 - 4193. 10.1109/TGRS.2011.2141672.

- [69] J. M. Bioucas-Dias, "A variable splitting augmented Lagrangian approach to linear spectral unmixing," *2009 First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, Grenoble, 2009, pp. 1-4.
- [70] AVIRIS. Aviris.jpl.nasa.gov [online]. [cit. 2020-05-04].
Dostupné z: <https://aviris.jpl.nasa.gov/aviris/index.html>
- [71] EO-1. Usgs.gov [online]. [cit. 2020-05-04].
Dostupné z: <https://archive.usgs.gov/archive/sites/eo1.usgs.gov/index.html>
- [72] Hyperspectral dataset. Sites.google.com [online]. [cit. 2020-05-04].
Dostupné z: <https://sites.google.com/site/hyperspectralcolorimaging/dataset>
- [73] Hyperspectral dataset. Manchester.ac.uk [online]. [cit. 2020-05-04]. Dostupné z: https://personalpages.manchester.ac.uk/staff/d.h.foster/Local_Illumination_HSIs/Local_Illumination_HSIs_2015.html
- [74] Hyperspectral dataset. Color.univ-lille.fr [online]. [cit. 2020-05-04].
Dostupné z: <http://color.univ-lille.fr/datasets/hytextila>
- [75] Getting Started with ENVI. Harrisgeospatial.com [online]. [cit. 2020-05-04].
Dostupné z: <https://www.harrisgeospatial.com/docs/gettingstartedwithenvi.html>
- [76] ENVI Image Files. Harrisgeospatial.com [online]. [cit. 2020-05-04].
Dostupné z: <https://www.harrisgeospatial.com/docs/ENVIImageFiles.html>
- [77] Baumgardner, M. F., Biehl, L. L., Landgrebe, D. A. (2015). 220 Band AVIRIS Hyperspectral Image Data Set: June 12, 1992 Indian Pine Test Site 3. Purdue University Research Repository. doi:10.4231/R7RX991C
- [78] Hyperspectral Imagery Synthesis (EIAs) toolbox. Computational Intelligence Group, University of the Basque Country / Euskal Herriko Unibertsitatea (UPV / EHU). Ehu.eus [online]. [cit. 2020-05-10]. Dostupné z: http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Imagery_Synthesis_tools_for_MATLAB
- [79] USGS Spectral Library. Usgs.gov [online]. [cit. 2020-05-10].
Dostupné z: <https://www.usgs.gov/labs/spec-lab/capabilities/spectral-library>
- [80] Osobní stránka: Jose Bioucas-Dias. Ix.it.pt [online]. [cit. 2020-05-11].
Dostupné z: <http://www.lx.it.pt/~bioucas/>

- [81] J. M. P Nascimento and J. M. Bioucas-Dias, "Hyperspectral signal subspace estimation," *2007 IEEE International Geoscience and Remote Sensing Symposium*, Barcelona, 2007, pp. 3225-3228, doi: 10.1109/IGARSS.2007.4423531.
- [82] Remote sensing laboratory datasets. rslab.ut.ac.ir [online]. [cit. 2020-07-23].
Dostupné z: <https://rslab.ut.ac.ir/data>
- [83] Funkce Spectral Match. mathworks.com [online]. [cit. 2020-07-29].
Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/41698-spectral-match?focused=3786765&tab=function>

11 Seznam obrázků

Obr. 1 - elektromagnetická vlna znázorněná v kartézských souřadnicích, vektory \mathbf{E} , \mathbf{H} leží v rovině os x a y, vektor \mathbf{k} směřuje ve směru osy z. [2]	10
Obr. 2 - elektromagnetické spektrum [3]	11
Obr. 3 - fotografie optického hranolu a znázornění principu rozkladu světla [7]	12
Obr. 4 - Znázornění dvou štěrbin na difrakční mřížce a závislosti rozdílu jejich vzdáleností od bodu interferenčního maxima na stínítku. [13].....	13
Obr. 5 - průběh amplitudy interferenčního obrazce na ploše stínítka v závislosti na počtu štěrbin N, pro: a) N = 2, b) N = 5, c) N = 10, d) N = 100. [9].....	14
Obr. 6 - Možnosti konstrukce difrakční mřížky [14]	14
Obr. 7 - Možnosti zobrazování prostorové a spektrální informace [15].....	15
Obr. 8 - hlavní části fotoaparátu nebo kamery ovlivňující vlastnosti optického paprsku před dopadem na obrazový senzor. [18]	16
Obr. 9 - spektrální křivky (reflectance curves) pro výběr několika běžných materiálů na zemském povrchu. Zobrazený v rozsahu vlnových délek viditelného a části infračerveného záření. [21].....	17
Obr. 10 - schéma zobrazující základní princip spektrometru [27].....	18
Obr. 11 - Princip Crossed Czerny-Turner Spectrometru [29] a ukázka možné konstrukce [23].....	19
Obr. 12 - Princip spektrometru s holografickou mřížkou [29] a ukázka možné konstrukce [30]....	19
Obr. 13 - Multispectral beamsplitting, barvo-dělicí hranol (vlevo), soustava polopropust. zrcadel (vpravo) [31]	20
Obr. 14 - Porovnání konstrukce staring multispektrální kamery s filtrovým kolem (136 x 124 x 105 mm) [34] a snapshot multispektrální kamery s mozaikovou strukturou filtru (52,5 x 52,5 x 79,4 mm) [35]	21
Obr. 15 - Ukázka spektrální charakteristiky snapshot kamery zobrazené na obrázku 14 vpravo [35]	21
Obr. 16 - základní princip hyperspektrální kamery [20]	22

Obr. 17 - znázornění datacube (prostorové dimenze x,y a informace o spektru λ) [31] [37]	22
Obr. 18 - ukázka detekce cizích objektů v mase a detekce množství tuků [38].....	23
Obr. 19 - Základní princip dálkového pasivního snímání satelitem (spaceborne remote sensing) [45]	24
Obr. 20 - analýza HSI dat v precizním zemědělství, na obrázcích je zobrazena detekce: a) plevel, b) mezer ve výsadbě, c) škůdců [46].....	24
Obr. 21 - Typické přístupy ke spektrálnímu zobrazování: a) whiskbroom, b) pushbroom, c) staring, d) snapshot [15].....	25
Obr. 22 - Znázornění jakou část datacube zaznamenávají jednotlivé metody za jednu expoziční dobu. a) skenovací metody (bodové skenování, řádkové skenování a pásmová sekvenční metoda) b) snapshot technologie spektrálního zobrazování. [31].....	27
Obr. 23 - Princip IFS-F metody spektrálního zobrazování [31]	28
Obr. 24 - Základní princip MAFC spektrálního zobrazování [33].....	28
Obr. 25 - Varianty systémů MAFC spektrálního zobrazování [31]	29
Obr. 26 - Spektrální rozsahy jednotlivých hyperspektrálních kamer od výrobce Resonon [56]	30
Obr. 27 - Základní řetězec zpracování hyperspektrálních dat.....	31
Obr. 28 - Schématické znázornění konverze hodnot HSI kamery před dalším zpracováním [50]..	32
Obr. 29 - Závislost atmosférické propustnosti na vlnové délce, za atmosférických běžných podmínek [21].....	33
Obr. 30, vlevo - Ukázka zobrazení konkrétního spektrálního vektoru v N-dimenzionálním spektrálním prostoru, pro nejjednodušší příklad (N = 2) [21] vpravo - Znázornění spekter odpovídajících 3 materiálům a jejich vzájemná spektrální vzdálenost (pro N=2) [21]	34
Obr. 31 - Ukázka spektrálního míchání v jednom pixelu [57].....	35
Obr. 32 - Význam Pure a mixed pixelu v hyperspektrálním zobrazování [58]	35
Obr. 33 - Tři možnosti vzniku spektrálního míchání [50].....	36
Obr. 34 - Vliv spektrálního míchání na reprezentaci dat ve spektrálním prostoru [50]	37
Obr. 35 - Dělení metod hyperspektrálního rozkladu	38
Obr. 36 - Grafické znázornění základní rovnice modelu lineárního spektrálního míchání (ukázkový případ bez šumu).....	39
Obr. 37 - Řetězec hyperspektrálního rozkladu [45]	41
Obr. 38 - Ilustrace odhadu tvaru konvexního obalu a spektrálních znaků endmembers (m_1 , m_2 , m_3) za využití metod: a) geometry - pure pixel based, b) geometry – minimum volume based, c) statistical [50].....	42
Obr. 39 - Schématické a grafické znázornění algoritmu PPI (rozšířená varianta s definováním úhlů natočení jednotlivých skewers) [65]	45
Obr. 40 - Ilustrace principu algoritmu VCA [64].....	46
Obr. 41 - Bodový graf (pro $\lambda_1 = 827\text{nm}$ a $\lambda_2 = 1780\text{nm}$) znázorňující HSI snímek tvořený třemi materiály, plnou čarou jsou propojené skutečné polohy endmembers, přerušovaně je znázorněn odhad VCA. a) data bez projekce, b) data promítnutá pomocí SVD. [64]....	47

Obr. 42, vlevo - znázornění minimálního konvexního obalu získaného regulací objemu $V(M)$ vpravo - vliv šumu způsobující nepřesné změření spektrálních vektorů a tím ovlivňující odhad konvexního obalu [61].....	49
Obr. 43 - Ukázka minimalizace objektivní funkce v algoritmu SISAL [61].....	51
Obr. 44 - Znázornění principu kvadratických MV regularizátorů [59].....	52
Obr. 45 - Význam regularizačního parametru beta [59]	53
Obr. 46 - Ukázka HSI snímku Indian Pines a jemu odpovídající GT [77]	56
Obr. 47 - Popis dvou běžných formátů dostupných HSI dat	58
Obr. 48 - Možnosti zobrazení HSI snímku. Nahoře je ukázka 2D náhledu 1. a 25. pásma snímku Indian Pines pomocí funkce <code>Zobrazeni_snimku_vsech_pasem</code> . Z obrázku vlevo je patrné, že informace z prvního pásma je znehodnocená šumem. Dole vlevo je zobrazen 2D náhled HSI snímku Salinas na 64. spektrálním pásmu (funkce <code>Zobrazeni_2D_nahledu</code>). Vpravo je 3D bodový graf tohoto snímku (funkce <code>Zobraz_3D_Scatterplot_real_data</code>)	59
Obr. 49 - GUI pro syntézu HSI snímku vytvořené v rámci projektu HYDRA (UPV / EHU) [78].	60
Obr. 50 - Popis formátu synteticky vytvořených dat.....	61
Obr. 51 - 2D náhled syntetického HSI snímku na 391. spektr. pásmu (funkce <code>Zobrazeni_2D_nahledu</code>). Vpravo je 3D bodový graf tohoto snímku (funkce <code>Zobraz_3D_Scatterplot</code>).....	61
Obr. 52 - Spektra jednotlivých endmembers a jim odpovídající abundances pro synteticky vygenerovaný HSI snímek (funkce <code>Zobrazeni_endmembers_a_abundances</code>).....	61
Obr. 53 - Vliv šumu na syntetizovaný HSI snímek (skript <code>zobrazeni_vlivu_sumu</code>).....	62
Obr. 54 - Ukázka spekter materiálů z kategorie Artificial o délce 480 spektrálních pásem.....	64
Obr. 55 – Spektra 3 vybraných vzorků kaolinitu a jejich vzájemné spektrální úhly [79]	65
Obr. 56 - Popis všech součástí výstupního souboru ze skriptu <code>generate_synthetic_HSI</code>	66
Obr. 57 - Porovnání syntetických snímků vygenerovaných podle dvou metod syntézy popsanych v této práci.....	67
Obr. 58 – Možnosti zobrazení vstupního HSI snímku.....	68
Obr. 59 - Princip algoritmu HySime: hledání minimální hodnoty sumy výkonu chyby projekce a výkonu šumu v závislosti na velikosti dimenze p . [81]	69
Obr. 60 – Vlevo je 2D projekce HSI snímku včetně odhadnutých a skutečných endmembers (Figure 4) Vpravo jsou průběhy odhadnutých a skutečných endmembers (Figure 5)	70
Obr. 61 – Shrnutí porovnání algoritmů hyperspektrálního rozkladu na syntetických HSI	72
Obr. 62 – Grafické znázornění závislosti průměrné odchylky spektrálních úhlů na SNR pro $n=3$ a $n=15$ (Pure pixel algoritmy a NMF-QMV-b dosahují shodných hodnot, a proto se jejich průběhy překrývají. Také se překrývají průběhy algoritmů NMF-QMV-c a NMF-QMV-t)	76
Obr. 63 - Grafické znázornění závislosti průměrné odchylky spektrálních úhlů na SNR pro $n=3$ a $n=15$ (Druhý graf obsahuje pouze průběh algoritmů SISAL a varianty algoritmu NMF-QMV).....	77
Obr. 64 - Opakování algoritmů HU pro shodný vstupní snímek.....	79

Obr. 65 - Vliv SNR na přesnost odhadu algoritmů HU, pro non-pure pixel snímky, včetně outliers	81
Obr. 66 – Vliv SNR, vlevo: 2. sada (non-pure pixels), vpravo: 3. sada (pure pixels)	81
Obr. 67 – Ukázka 2D projekcí odhadnutých endmembers podle jednotlivých algoritmů (figures 04). Na posledním obrázku jsou viditelné 2 nepřesně odhadnuté endmembers (VCA a AVMAX) a jejich spektrální průběhy (Figure 05).....	82
Obr. 68 – Závislost průměrných odchylek spektrálních úhlů na počtu endmembers, vlevo: pure pixel data, vpravo: non-pure pixel.....	83
Obr. 69 – Ukázky výstupních Figures 04 a 05 pro test vlivu počtu endmembers (pro n=5 a n=12)	84
Obr. 70 – 2D náhledy vybraných HSI: vlevo Jasper Ridge a vpravo Cuprite	86
Obr. 71 - Procentuální rozložení odhadnutých materiálů na snímku Jasper Ridge podle algoritmu NMF-QMV	86
Obr. 72 - Porovnání spekter odhadnutých a referenčních materiálů snímku Jasper Ridge.....	87
Obr. 73 – Ukázky porovnání spekter odhadnutých a referenčních materiálů snímku Cuprite	89

12 Seznam zkratek a symbolů

12.1 Anglické pojmy

Endmembers	Hlavní složky hyperspektrální analýzy odpovídající materiálům obsaženým ve snímané scéně
Abundance	Veličina vyjadřující procentuální zastoupení materiálů v jednotlivých pixelech
Unmixing	Metoda analýzy hyperspektrálních dat umožňující zpětný rozklad endmembers a abundances z dat ovlivněných spektrálním mícháním
Pure pixel	Buňka datacube se spektrálním znakem přesně odpovídající konkrétnímu endmembru

12.2 Zkratky

Základní pojmy	
HSI	(<i>HyperSpectral Imaging</i>) - hyperspektrální zobrazování
HU	(<i>Hyperspektral Unmixing</i>) - hyperspektrální rozklad
RTT	(<i>Radiative Transfer Theory</i>) - nelineární model hyperspektrálního rozkladu
LMM	(<i>Linear Mixing Model</i>) - lineární model hyperspektrálního rozkladu
ANC	(<i>Abundance Nonnegativity Constraint</i>) - podmínka nezápornosti pro vektory abundance matrix
ASC	(<i>Abundance Sum to one Constraint</i>) - podmínka sumy do jedné pro abundances daného pixelu
SR	(<i>Sparse Regression</i>) – metoda řídké regrese
MV	(<i>Minimum Volume</i>) – metody HU hledající minimální objem konvexního obalu
GT	(<i>Ground Truth</i>) – informace o rozložení materiálů na snímané scéně
Kapitola Preprocessing	
DN	(<i>Digital Numbers</i>) - digitální hodnoty zaznamenané na senzoru, které je třeba kalibrovat
TOA	(<i>Top Of Atmosphere</i>) - označení radiance, u které ještě nebyly eliminovány atmosférické jevy
RTM	(<i>Radiative Transfer Model</i>) - model popisující atmosférické jevy
BRDF	(<i>Bidirectional Reflectance Distribution Functions</i>) - funkce popisující vliv geometrie snímané scény
Znamé metody analýzy signálů	
BSS	<i>Blind Source Separation</i>
PCA	<i>Principal Component Analysis</i>
MNF	<i>Minimum Noise Fraction</i>
ICA	<i>Independent Component Analysis</i>
MCMC	<i>Markov Chain Monte Carlo</i>
Geometrické metody odhadu endmembers - Pure pixel based	
PPI	<i>Pixel Purity Index</i>

VCA	<i>Vertex Component Analysis</i>
SGA	<i>Simplex Growing Algorithm</i>
SVMAX	<i>Successive Volume MAXimization</i>
RSSNMF	<i>the RecurSive algorithm for Separable Nonnegative Matrix Factorization</i>
N-FINDR	(-)
IEA	<i>Iterative Error Analysis</i>
SMACC	<i>Sequential Maximum Angle Convex Cone</i>
AVMAX	<i>Alternating Volume MAXimization</i>
Geometrické metody odhadu endmembers - MV based	
CCA	<i>Convex Cone Analysis</i>
ICE	<i>Iterative Constrained Endmembers</i>
SPICE	<i>Sparsity-Promoting Iterative Constrained Endmembers</i>
MVC-NMF	<i>Minimum Volume transform - Nonnegative Matrix Factorization</i>
MVSA	<i>Minimum Volume Simplex Analysis</i>
MVES	<i>Minimum Volume Enclosing Simplex</i>
SISAL	<i>Simplex Identification via variable Splitting and Augmented Lagrangian</i>

12.3 Proměnné

Linear Mixing Model (LMM)			
Y	matice zaznamenaných dat	Observed data matrix	$\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_x]$
x	počet pixelů	-	-
y	vektor změřených hodnot radiance v daném pixelu	-	$\mathbf{y}_I = [y_{I1}, \dots, y_{IN}]$
N	počet spektrálních pásem	-	-
M	matice spektrálního míchání	Mixing matrix	$\mathbf{M} = [\mathbf{m}_1, \dots, \mathbf{m}_p]$
m	spektrální znak o délce N	Spectral signature	$\mathbf{m}_1 = [m_1, \dots, m_{1N}]$
p	celkový počet obsažených materiálů	Number of endmembers	-
α	matice procentuálního zastoupení jednotlivých materiálů	Abundance matrix	$\boldsymbol{\alpha} = [\boldsymbol{\alpha}_1, \dots, \boldsymbol{\alpha}_x]$
α_i	procentuální zastoupení i-tého materiálu	Abundance	$\boldsymbol{\alpha}_i = [\alpha_{i1}, \dots, \alpha_{iN}]$, $\alpha_i \in (0,1)$
i	index pro jednotlivé materiály	-	$i = 1, \dots, p$
N	šumová matice	Noise matrix	-
Formulace MV algoritmů			
$V(\mathbf{M})$	regularizér objemu	Volume regularizer	-
β	regularizační parametr	Regularization parameter	-

13 Seznam příloh

Název souboru	Formát	Autor*	Pozn.	Str.v textu
Bez složky				
Main_script_TymesP	skript .m	-	hlavní skript	68-75
Generate_paths	skript .m	-	vytvoření cest v Matlabu	-
Složka: 1_Vytvoreni_databaze_endmembers				
create_e_database	skript .m	-	převod spektr. knihovny do formátu .m	63-64
create_e_database_pruned	skript .m	-	omezení knihovny podle spektr. úhlu	65
e_database_480	data .m	-	knihovna spekter o délce 480 pásem	-
e_database_480_pruned_3	data .m	-	^ omezená knihovna spektr. úhlem 3°	-
e_database_480_pruned_5	data .m	-	^ omezená knihovna spektr. úhlem 5°	-
Podsložka: Hyperspectral Synthesis (HYDRA)				60
synthetic_run	GUI .m	CIG	GUI pro vytvoření Syntetických snímků	60
getEndmembers	funkce .m	CIG	nahrání .asc souborů do workspace	64
USGS Spectral library	.acs soubory	USGS	USGS spektr. knihovna ve formátu .asc	63
Složka: 2_Synteza_HSI_snimku				
generate_synthetic_HSI	skript .m	-	skript na vytvoření synthetic snímků	66
spectMixGen	funkce .m	JBD	funkce na vytvoření synthetic snímků	66
Pridani_sumu	skript .m	-	přidání SNR k syntetickým snímkům	62
zobrazeni_vlivu_sumu	skript .m	-	^ zobrazení dat pro různá SNR	62
Složka: 3_Synteticke_snimky				
Vybrané Syntetické snímky	data .m	-	data vytvořená pro testování	76-84
Vyhodnocení testů	.xlsx	-	tabulky s výsledky testů	76-84
Výstupy z Matlabu	.fig a .png	-	výstupy uložené ve 2 formátech	76-84
Složka: 4_Realne_snimky				
Vybrané snímky	data .m	-	data vybraná pro testování	85-89
Vyhodnocení testů	.xlsx	-	tabulky s výsledky testů	85-89
Výstupy z Matlabu	.fig a .png	-	výstupy uložené ve 2 formátech	85-89
Složka: Matlab_funkce_a_toolboxy				
SpectraMatch	funkce .m	MA	porovnání odhad. a referenčních spekter	72
Podsložka: NMF-QMV_demo-master				
NMF_QMV	funkce .m	JBD	algoritmy NMF-QMV	-

Název souboru	Formát	Autor*	Pozn.	Str.v textu
Složka: Matlab_funkce_a_toolboxy				
Podsložka: unmixing_overview_demo				
hysime	funkce .m	JBD	<i>funkce pro odhad počtu endmembers</i>	69
nfindr	funkce .m	JBD	<i>algoritmus N-FINDR</i>	-
VCA	funkce .m	JBD	<i>algoritmus VCA</i>	-
sisal	funkce .m	JBD	<i>algoritmus SISAL</i>	-
Podsložka: davidkun - HyperSpectral Toolbox - v0.07-61 - gaaeabad				
hyperAvmax	funkce .m	DK	<i>algoritmus AVMAX</i>	-
hyperPpi	funkce .m	DK	<i>algoritmus PPI</i>	-
hyperVca	funkce .m	DK	<i>algoritmus VCA (nepoužitý)</i>	-
hyperNfindr	funkce .m	DK	<i>algoritmus N-FINDR (nepoužitý)</i>	-
Složka: Matlab_funkce_PT				
Prevod_na_typ1	funkce .m	-	<i>HSI typ1: (x,y,N)</i>	58
Prevod_na_typ2	funkce .m	-	<i>HSI typ2: 1x1 struct (nRow, nCol, nBand, Y)</i>	58
Porovnani_s_databazi	funkce .m	-	<i>porovnání odhad. a ref. spekter mezi původní a odhad. maticí M (nepoužito)</i>	71-72
Vypocet_odchylky	funkce .m	-	<i>2D náhled pro definované spektr. pásmo</i>	-
Zobrazeni_2D_nahledu	funkce .m	-	<i>3D bodový graf pro definované vln. délky</i>	59, 61
Zobraz_3D_Scatterplot	funkce .m	-	<i>spektra na jednotlivých pixelech</i>	-
Zobrazeni_endmembers_a_abundances	funkce .m	-	<i>endm. a jim odpovídající abund.</i>	61
Zobrazeni_snimku_vsech_pasem	funkce .m	-	<i>všecha pásma formou videa</i>	59
Zobrazeni_projekce_endmembers	funkce .m	-	<i>2D scatterplot s vyznačenými odhadnutými endm.</i>	70
Zobrazeni_spektra_endmembers	funkce .m	-	<i>Spektra odhadnutých endm.</i>	70

*Autoři:

CIG Computational Intelligence Group, university of the Basque Country [78]

USGS United States Geological Survey - spektrální knihovna [79]

JBD Jose Bioucas Dias (Univesity de Lisboa) a jeho spolupracovníci [50], [60], [61], [69], [80], [81]

MA Mohammad Abouali (Mathworks Community) [83]

DK David Kun (github.com/davidkun) [63]