

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA STROJNÍHO INŽENÝRSTVÍ
ÚSTAV MATEMATIKY
FACULTY OF MECHANICAL ENGINEERING
INSTITUTE OF MATHEMATICS

NORMALIZACE HYPERSPEKTRÁLNÍCH OBRAZOVÝCH DAT

NORMALIZATION OF HYPERSPECTRAL IMAGE DATA

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. TOMÁŠ GRÍSA

VEDOUCÍ PRÁCE
SUPERVISOR

doc. PaedDr. Dalibor Martišek, Ph.D.

BRNO 2013

Vysoké učení technické v Brně, Fakulta strojního inženýrství

Ústav matematiky

Akademický rok: 2012/2013

ZADÁNÍ DIPLOMOVÉ PRÁCE

student(ka): Bc. Tomáš Grísa

který/která studuje v **magisterském navazujícím studijním programu**

obor: **Matematické inženýrství (3901T021)**

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma diplomové práce:

Normalizace hyperspektrálních obrazových dat

v anglickém jazyce:

Normalization of hyperspectral image data

Stručná charakteristika problematiky úkolu:

Práce se bude zabývat hyperspektrálními obrazovými daty pořízenými při leteckém snímání zemského povrchu, zvláště pak metodami jejich normalizace vzhledem k úhlu snímání.

Cíle diplomové práce:

Cílem práce bude vyrovnání spekter odrazivosti napříč šířkou letové linie. Východiskem je statistická analýza spekter napříč linií, cílem následné vyrovnání vzhledem k ortogonálnímu směru. Součástí práce bude rovněž optimalizace algoritmu pro různé druhy povrchů.

Seznam odborné literatury:

Hlaváč, V. Šonka, M.: Počítačové vidění, Grada, Praha, 1992

Shunlin Liang: Quantitative remote sensing of land surfaces, John Wiley & Sons, 2003

Karpíšek, Z.: Matematika IV - statistika a pravděpodobnost, CERM, Brno, 2007

Vedoucí diplomové práce: doc. PaedDr. Dalibor Martišek, Ph.D.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2012/2013.

V Brně, dne 5.11.2012

L.S.

prof. RNDr. Josef Šlapal, CSc.
Ředitel ústavu

prof. RNDr. Miroslav Doupovec, CSc., dr. h. c.
Děkan fakulty

Abstrakt

Letecký hyperspektrální dálkový průzkum Země slouží pro monitorování a analýzu různých složek životního prostředí. Tato práce se zabývá hyperspektrálními obrazovými daty, především jejich normalizací vzhledem k úhlu snímání. Je navržen a popsán algoritmus, jehož východiskem je statistická analýza spekter napříč linií a fyzikální modely popisující průběh spektrální odrazivosti. Důležitou součástí je softwarová implementace tohoto algoritmu, umožňující výpočet požadované normalizace pro reálné datové soubory.

Abstract

The airborne hyperspectral remote sensing is used as an approach to monitor and analyse actual state of environmental components. This thesis deals with hyperspectral image data, especially it is focused on normalization with respect to scanning angle. The thesis proposes specific algorithm, which is based on the statistical analysis of spectral lines across the scan line and on a physical models describing the process of spectral reflectance. An important part of this thesis is software implementation of proposed algorithm, that allows to calculate required normalization for real datasets.

Klíčová slova

hyperspektrální obrazová data, dálkový průzkum Země, nadir normalizace, BRDF, BRDF modely

Key words

hyperspectral image data, remote sensing, nadir normalization, BRDF, BRDF models

Prohlašuji, že jsem diplomovou práci *Normalizace hyperspektrálních obrazových dat* vypracoval samostatně pod vedením doc. PaedDr. Dalibora Martiška, Ph.D. s použitím materiálů uvedených v seznamu literatury.

Bc. Tomáš Grísa

Děkuji svému školiteli doc. PaedDr. Daliboru Martiškovi, Ph.D. za četné rady a připomínky při vedení mé práce. Děkuji Ing. Janu Novotnému, Ing. Janu Hanušovi a Doc. Mgr. Ing. Františku Zemkovi, Ph.D. z CVGZ AV ČR za odborné konzultace.

Děkuji CVGZ AV ČR za poskytnutí letových linií hyperspektrálních obrazových dat, která byla pořízena s finanční podporou projektu CzechGlobe (OP VaVpl, Reg. č. CZ.1.05/1.1.00/02.0073) a výzkumné infrastruktury CzeCOS (MŠMT, Reg. č. LM2010007).

Bc. Tomáš Grísa

Obsah

Úvod	13
1 Teoretické základy	15
1.1 Popisná statistika	15
1.2 Problém nejmenších čtverců	15
1.2.1 Spádové metody	18
1.2.2 Nelineární problém nejmenších čtverců	19
1.2.3 Gauss-Newtonova metoda	20
1.2.4 Levenberg–Marquardtův algoritmus	20
2 Dálkový průzkum Země	23
2.1 Definice a význam dálkového průzkumu Země	23
2.2 Fyzikální podstata dálkového průzkumu Země	23
2.2.1 Radiometrické veličiny	24
2.2.2 Odrazivost a albedo	25
2.2.3 Charakteristika základních oblastí elektromagnetického spektra využitelných v DPZ	28
2.2.4 Spektrální chování objektů	29
3 Zpracovávaná data	31
3.1 Způsob snímání	31
3.2 Význam dat	32
3.3 Reprezentace dat	33
3.4 Předzpracování dat	34
3.4.1 Radiometrické korekce	34
3.4.2 Atmosférické korekce	35
4 Nadir normalizace	37
4.1 Popis problému	37
4.2 Způsob řešení	38
4.2.1 Klasifikace tříd pokryvu	38
4.2.2 Statistická charakteristika sloupců	41
4.2.3 BRDF modely	43
4.3 Výsledná normalizace	46
5 Softwarová implementace	49
5.1 Popis jednotlivých skriptů	49
5.1.1 Vizualizace datového souboru	50
5.1.2 Nadir normalizace	51
5.2 Shrnutí	51
6 Zhodnocení funkčnosti implementovaného algoritmu	53
6.1 Porovnání jednotlivých BRDF modelů	53
6.2 Zhodnocení	54

Závěr	57
Literatura	59
Seznam obrázků	61
Seznam tabulek	63

Úvod

Téma této práce vzniklo ve spolupráci s Centrem výzkumu globální změny AV ČR, kde se zabývají snímkováním určitých lokalit zemského povrchu na území ČR pomocí metod dálkového průzkumu — jedná se o distanční zkoumání a měření zemského povrchu. Takto naměřená data slouží pro fyzikálně založené odhady biofyzikálních a biochemických parametrů vegetace. Každou analýzu předchází tzv. *předzpracování* naměřených dat. Toto zahrnuje metody pro odstranění nepřesností měření, které jsou způsobeny různými vlivy.

Tato práce se zabývá jednou z těchto metod předzpracování — normalizací hyperspektrálních obrazových dat pořízených při leteckém snímkování zemského povrchu vzhledem k úhlu snímání, neboli tzv. *nadir normalizací*. Cílem práce je navržení postupu pro vyrovnání spekter odrazivosti napříč šířkou letové linie, přičemž východiskem je statistická analýza spekter napříč linií. Využívají se zde také fyzikální modely odrazivosti, pomocí kterých je vypočítávána normalizační funkce. Avšak každá třída objektů a pokryvů se chová velmi odlišně. Proto je pak velmi důležité, aby bylo možno provádět požadovanou normalizaci pro jednotlivé druhy povrchů zvlášť.

V první kapitole jsou uvedeny vybrané teoretické základy z různých oblastí matematiky, které jsou podkladem pro teoretické i praktické metody a algoritmy řešení dále popsaného problému.

Druhá kapitola se zabývá podrobnějším popisem dálkového průzkumu Země — jeho definicí a fyzikální podstatou. Jsou zde popsány radiometrické veličiny a odvození důležitých vztahů pro popis snímaných dat.

Ve třetí kapitole je blíže popsán konkrétní způsob snímání hyperspektrálních dat, jejich význam a různé metody reprezentace a vizualizace těchto dat. Navíc jsou zde uvedeny základní přístupy k předzpracování hyperspektrálních dat.

Samotná problematika nadir normalizace je popsána v kapitole čtvrté. Tato kapitola se také věnuje podrobnému popisu jednotlivých kroků navrženého postupu pro výpočet této normalizace. Pro názornost jsou zde použity grafické výstupy z výpočtů na reálných datových souborech.

Důležitou součástí je programová implementace uvedeného postupu, která slouží k výpočtu nadir normalizace pro reálné datové soubory. Popisem této implementace se zabývá pátá kapitola, kde jsou blíže popsány jednotlivé, autorem naprogramované skripty. Z důvodu kvalitní implementace základních rutinních matematických operací a algoritmů (pro potřeby této práce především algoritmů pro řešení problému nejmenších čtverců) je pro programovou implementaci zvoleno programové prostředí MATLAB. Využití a porovnání výsledků této implementace na reálných letových liniích hyperspektrálních obrazových dat, které pro účely této práce poskytlo CVGZ, je uvedeno v kapitole šesté.

1 Teoretické základy

V této kapitole jsou uvedeny teoretické základy z různých oblastí matematiky, které budou využity v dalších částech této práce.

1.1 Popisná statistika

Zde jsou uvedeny základní pojmy a definice popisné statistiky, viz. [6].

Soubor individuálních údajů o objektech se nazývá *základní soubor*. Zkoumané objekty jsou tzv. *statistické jednotky* a jsou u nich sledovány vytipované vlastnosti — *statistické znaky* (veličiny), které nabývají pozorovaných *hodnot*.

Hodnoty znaku pozorované na n statistických jednotkách tvoří *statistický soubor s rozsahem n* . Pro jednorozměrný znak X je získán *jednorozměrný statistický soubor* (x_1, \dots, x_n) , kde x_i je *pozorovaná hodnota* znaku X u i -té statistické jednotky, $i = 1, \dots, n$. Dle potřeby lze tento statistický soubor uspořádat podle rostoucích hodnot x_i . Jedná se pak o *uspořádaný statistický soubor* $(x_{(1)}, \dots, x_{(n)})$, kde $x_{(i)} \leq x_{(i+1)}$ pro všechny indexy i .

Definice 1. *Aritmetický průměr* statistického souboru je číslo

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i.$$

Definice 2. *Medián* statistického souboru je číslo

$$\tilde{x} = \begin{cases} x_{(\frac{n+1}{2})} & \text{pro lichá } n, \\ \frac{1}{2} [x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}] & \text{pro sudá } n. \end{cases}$$

Poznámka 3. *Medián* rozděluje podle velikosti seřazený jednorozměrný statistický soubor na dvě stejně početné poloviny. Jde o *robustní* charakteristiku, která je oproti průměru málo citlivá na extrémně odchýlené hodnoty.

Definice 4. *Modus* je hodnota, která se v daném statistickém souboru vyskytuje nejčastěji, resp. je to hodnota znaku s největší absolutní četností.

Poznámka 5. *Aritmetický průměr, medián a modus* jsou tzv. *základní charakteristiky polohy* statistického souboru.

1.2 Problém nejmenších čtverců

Dále uvedené pojmy a definice byly čerpány ze zdrojů [2], [3] a [9].

Uvažujme následující obecný problém: Máme funkci $F : \mathbb{R}^n \rightarrow \mathbb{R}$ a chceme najít takový její argument, abychom dostali minimální hodnotu této funkce.

Definice 6. Necht $F : \mathbb{R}^n \rightarrow \mathbb{R}$. Uvažujme takové \mathbf{x}^+ , pro které platí

$$\mathbf{x}^+ = \arg \min_{\mathbf{x}} \{F(\mathbf{x})\}.$$

Potom řekneme, že \mathbf{x}^+ *minimalizuje funkci F globálně*.

Řešit tento problém je ovšem obecně velmi náročné, proto se častěji používají pro výpočet metody, které hledají tento argument funkce F pouze lokálně.

Definice 7. Necht $F : \mathbb{R}^n \rightarrow \mathbb{R}$, $\delta \in \mathbb{R}$, $\delta > 0$. Uvažujme takové \mathbf{x}^* , pro které platí

$$F(\mathbf{x}^*) \leq F(\mathbf{x}), \quad \text{pro } \forall \mathbf{x} : \|\mathbf{x} - \mathbf{x}^*\| < \delta.$$


Potom řekneme, že \mathbf{x}^* *minimalizuje funkci F lokálně*.

Definice 8. *Problém nejmenších čtverců* definujme jako problém hledání právě takového \mathbf{x} , které lokálně minimalizuje výraz¹

$$F(\mathbf{x}) = \frac{1}{2} \sum_{i=1}^m (f_i(\mathbf{x}))^2,$$

kde $f_i : \mathbb{R}^n \rightarrow \mathbb{R}$, $i = 1, \dots, m$ jsou zadané funkce a $m \geq n$.

Příklad 9. S problémem nejmenších čtverců se můžeme často setkat při prokládání naměřených dat křivkou požadovaného tvaru. Předpokládejme množinu naměřených dat $(t_1, y_1), \dots, (t_m, y_m)$, kterou chceme proložit křivkou tvaru $M(\mathbf{x}, t) = x_2 e^{x_1 t} + x_3$.



Obrázek 1.1: Naměřená data $\{(t_i, y_i)\}$ (ozn. +) proložená křivkou $M(\mathbf{x}^*, t)$.

Model tedy závisí na parametrech $\mathbf{x} = [x_1, x_2, x_3]^\top$. Nyní předpokládejme, že existuje takové \mathbf{x}^\dagger , pro které platí $y_i = M(\mathbf{x}^\dagger, t_i) + \varepsilon_i$, kde ε_i jsou chyby měření (u kterých

¹Koeficient $\frac{1}{2}$ v definici $F(\mathbf{x})$ nemá vliv na \mathbf{x}^* . Jak bude dále uvedeno, je zde z důvodu vhodné úpravy.

se předpokládá, že se chovají jako tzv. *bílý šum*²). Při prokládání dat křivkou pomocí metody nejmenších čtverců se snažíme minimalizovat součet kvadrátů *reziduí* (odchylek). Podle definice 8 označme tato rezidua f_i . Potom pro každou volbu parametru \mathbf{x} je lze spočítat následovně

$$\begin{aligned} f_i(\mathbf{x}) &= y_i - M(\mathbf{x}, t_i) \\ &= y_i - x_2 e^{x_1 t_i} - x_3, \quad i = 1, \dots, m. \end{aligned}$$

Vhodným algoritmem pro řešení problému nejmenších čtverců tedy hledáme takové parametry \mathbf{x}^* , které minimalizují součet kvadrátů reziduí. Je vidět, že se jedná o problém nejmenších čtverců podle definice 8, kde $n = 3$. Jak by naměřená data a příslušná křivka $M(\mathbf{x}^*, t)$ mohli vypadat znázorňuje obrázek 1.1. \square

Nyní předpokládejme, že F je diferencovatelná a dostatečně hladká tak, aby ji bylo možno rozvinout pomocí *Taylorova rozvoje*

$$F(\mathbf{x} + \mathbf{h}) = F(\mathbf{x}) + \mathbf{h}^\top \mathbf{g} + \frac{1}{2} \mathbf{h}^\top \mathbf{H} \mathbf{h} + O(\|\mathbf{h}\|^3), \quad (1.1)$$

kde \mathbf{g} je *gradient*

$$\mathbf{g} \equiv \mathbf{F}'(\mathbf{x}) = \begin{bmatrix} \frac{\partial F}{\partial x_1}(\mathbf{x}) \\ \vdots \\ \frac{\partial F}{\partial x_n}(\mathbf{x}) \end{bmatrix}, \quad (1.2)$$

a \mathbf{H} je tzv. *Hessova matice*

$$\mathbf{H} \equiv \mathbf{F}''(\mathbf{x}) = \left[\frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x}) \right]. \quad (1.3)$$

Pokud \mathbf{x}^* minimalizuje F lokálně a velikost $\|\mathbf{h}\|$ je dostatečně malá, pak neexistuje bod $\mathbf{x}^* + \mathbf{h}$, ve kterém by měla funkce F menší hodnotu. Pak podle Taylorova rozvoje platí následující věta.

Věta 10. Nutná podmínka lokálního minima

Pokud \mathbf{x}^ minimalizuje funkci F lokálně, pak*

$$\mathbf{g}^* \equiv \mathbf{F}'(\mathbf{x}^*) = 0.$$

Definice 11. Pokud platí

$$\mathbf{g}_s \equiv \mathbf{F}'(\mathbf{x}_s) = 0,$$

pak se \mathbf{x}_s nazývá *stacionární bod* funkce F .

Lokální minimum je tedy stacionárním bodem, avšak totéž platí i pro lokální maximum. Navíc může platit, že stacionární bod není lokálním minimem, ani lokálním maximem. Takovýto bod se nazývá *sedlový*. Aby se určilo, zda je stacionární bod opravdu lokálním

²Každý prvek má rozdělení pravděpodobnosti s nulovou střední hodnotou, konečným rozptylem a prvky jsou navzájem nezávislé.

minimem, je nutné se v Taylorově rozvoji zabývat členem s druhými derivacemi. Pokud tedy do Taylorova rozvoje dosadíme \mathbf{x}_s místo \mathbf{x} , pak pro lokální minimum plyne, že symetrická matice \mathbf{H} musí být pozitivně definitní (její vlastní čísla jsou větší než $\delta > 0$). Odtud pak platí, že

$$\mathbf{h}^\top \mathbf{H} \mathbf{h} > \delta \|\mathbf{h}\|^2. \quad (1.4)$$

Nyní lze tedy formulovat postačující podmínku pro lokální minimum.

Věta 12. Postačující podmínka lokálního minima

Nechť je \mathbf{x}_s stacionární bod a $\mathbf{F}''(\mathbf{x}_s)$ je pozitivně definitní. Potom \mathbf{x}_s minimalizuje F lokálně.

1.2.1 Spádové metody

Problém nejmenších čtverců je obecně řešitelný pomocí metod nelineární optimalizace. Všechny tyto metody jsou tzv. *iterativní*. To znamená, že ze zvoleného startovacího bodu \mathbf{x}_0 generuje algoritmus posloupnost bodů $\mathbf{x}_1, \mathbf{x}_2, \dots$, která (v ideálním případě) konverguje k bodu \mathbf{x}^* , jenž lokálně minimalizuje funkci F . Většina těchto metod využívá tzv. *podmínku spádu*, kdy platí

$$F(\mathbf{x}_{k+1}) < F(\mathbf{x}_k). \quad (1.5)$$

Toto zabrání konvergenci k maximu či sedlovému bodu. Avšak pokud má funkce F více lokálních minim, výsledek závisí na startovacím bodu \mathbf{x}_0 . Dále je důležitým krokem spádových metod nalezení vhodného směru.

Definice 13. Řekneme, že \mathbf{h} je *spádovým směrem* funkce F v bodě \mathbf{x} , pokud platí

$$\mathbf{h}^\top \mathbf{F}'(\mathbf{x}) < 0.$$

Pokud takovýto směr neexistuje, pak $\mathbf{F}'(\mathbf{x}) = 0$ a \mathbf{x} je stacionárním bodem. Nyní bude uveden základní algoritmus spádových metod, který splňuje podmínku 1.5.

Algoritmus 1: Spádová metoda

```

begin
   $k := 0; \mathbf{x} := \mathbf{x}_0; nalezeno := \text{false};$  // startovací bod
  while (not nalezeno) and ( $k < k_{max}$ ) do
     $\mathbf{h}_d := \text{najdi\_smer}(\mathbf{x});$  // z bodu x ve směru spádu
    if hledané  $\mathbf{h}_d$  neexistuje then
       $nalezeno := \text{true};$  // bod x je stacionární bod
    else
       $\alpha := \text{delka\_kroku}(\mathbf{x}, \mathbf{h}_d);$  // z bodu x ve směru  $\mathbf{h}_d$ 
       $\mathbf{x} := \mathbf{x} + \alpha \mathbf{h}_d; k = k + 1;$  // další iterace
    end if
  end while
end

```

V každé iteraci algoritmu se tedy hledá vhodný spádový směr a délka kroku, která zajistí dostatečný pokles funkce F . Jedním ze způsobů je hledání takové délky (nebo alespoň její aproximace), aby platilo

$$\alpha_e = \arg \min_{\alpha > 0} \{F(\mathbf{x} + \alpha \mathbf{h})\}. \quad (1.6)$$

Existuje mnoho různých spádových metod, které se liší právě ve výpočtu délky kroku či spádového směru. Jednou z nejjednodušších je *metoda největšího spádu*, kde jak již z názvu plyne $\mathbf{h} = \mathbf{F}'(\mathbf{x})$. Popis dalších spádových metod lze nalézt v [9], str. 7–16.

1.2.2 Nelineární problém nejmenších čtverců

Pro potřeby této práce je ale nutné řešit tzv. nelineární problém nejmenších čtverců. Ve smyslu definice 8 to znamená, že funkce f_i nejsou lineární vzhledem k \mathbf{x} . Mějme vektorovou funkci $\mathbf{f} : \mathbb{R}^n \rightarrow \mathbb{R}^m$, kde $m \geq n$. Snahou je tedy minimalizovat $\|\mathbf{f}(\mathbf{x})\|$, případně ekvivalentně najít

$$\mathbf{x}^* = \arg \min_{\mathbf{x}} \{F(\mathbf{x})\}, \quad (1.7)$$

kde

$$F(\mathbf{x}) = \frac{1}{2} \sum_{i=1}^m (f_i(\mathbf{x}))^2 = \frac{1}{2} \|\mathbf{f}(\mathbf{x})\|^2 = \frac{1}{2} \mathbf{f}(\mathbf{x})^\top \mathbf{f}(\mathbf{x}). \quad (1.8)$$

Jak již bylo uvedeno, takovýto problém lze řešit pomocí obecných optimalizačních metod, avšak existují vhodnější metody speciálně zaměřené na nelineární problém nejmenších čtverců.

Než budou popsány dvě vhodné metody pro řešení, je třeba určit vztahy pro první a druhou derivaci F . Předpokládejme, že \mathbf{f} má spojitě všechny parciální derivace prvního a druhého řádu. Potom můžeme napsat *Taylorův rozvoj*

$$\mathbf{f}(\mathbf{x} + \mathbf{h}) = \mathbf{f}(\mathbf{x}) + \mathbf{J}(\mathbf{x}) \mathbf{h} + O(\|\mathbf{h}\|^2), \quad (1.9)$$

kde $\mathbf{J} \in \mathbb{R}^{m \times n}$ je *Jacobiho matice*, která je definována pomocí vztahu

$$(\mathbf{J}(\mathbf{x}))_{ij} = \frac{\partial f_i}{\partial x_j}(\mathbf{x}). \quad (1.10)$$

Nyní tedy lze pro $F : \mathbb{R}^n \rightarrow \mathbb{R}$ napsat³

$$\frac{\partial F}{\partial x_j}(\mathbf{x}) = \sum_{i=1}^m f_i(\mathbf{x}) \frac{\partial f_i}{\partial x_j}(\mathbf{x}). \quad (1.11)$$

Dostáváme tedy gradient $\mathbf{g} \equiv \mathbf{F}'(\mathbf{x})$ ve tvaru

$$\mathbf{F}'(\mathbf{x}) = \mathbf{J}(\mathbf{x})^\top \mathbf{f}(\mathbf{x}). \quad (1.12)$$

Dále je také třeba určit Hessovu matici $\mathbf{H} \equiv \mathbf{F}''(\mathbf{x})$. Pro člen na pozici (j, k) tedy platí

$$\frac{\partial^2 F}{\partial x_j \partial x_k}(\mathbf{x}) = \sum_{i=1}^m \left(\frac{\partial f_i}{\partial x_j}(\mathbf{x}) \frac{\partial f_i}{\partial x_k}(\mathbf{x}) + f_i(\mathbf{x}) \frac{\partial^2 f_i}{\partial x_j \partial x_k}(\mathbf{x}) \right). \quad (1.13)$$

³Pokud by v definici 8 nebyl použit koeficient $\frac{1}{2}$, vyskytoval by se naopak v mnoha dalších úpravách násobek koeficientem 2.

Odtud pak plyne

$$\mathbf{F}''(\mathbf{x}) = \mathbf{J}(\mathbf{x})^\top \mathbf{J}(\mathbf{x}) + \sum_{i=1}^m f_i(x) \mathbf{f}''_i(\mathbf{x}). \quad (1.14)$$

Další dvě podsekcce se věnují metodám pro řešení nelineárního problému nejmenších čtverců, které patří mezi spádové metody a vycházejí z algoritmu 1.

1.2.3 Gauss-Newtonova metoda

Tato metoda je založena na lineární aproximaci prvků \mathbf{f} v okolí \mathbf{x} . Z Taylorova rozvoje lze ukázat, že pro malé $\|\mathbf{h}\|$ platí

$$\mathbf{f}(\mathbf{x} + \mathbf{h}) \simeq \boldsymbol{\ell}(\mathbf{h}) \equiv \mathbf{f}(\mathbf{x}) + \mathbf{J}(\mathbf{x}) \mathbf{h}. \quad (1.15)$$

Dosazením do vztahu 1.8 obdržíme

$$\begin{aligned} F(\mathbf{x} + \mathbf{h}) \simeq L(\mathbf{h}) &\equiv \frac{1}{2} \boldsymbol{\ell}(\mathbf{h})^\top \boldsymbol{\ell}(\mathbf{h}) \\ &= \frac{1}{2} \mathbf{f}^\top \mathbf{f} + \mathbf{h}^\top \mathbf{J}^\top \mathbf{f} + \frac{1}{2} \mathbf{h}^\top \mathbf{J}^\top \mathbf{J} \mathbf{h} \\ &= F(\mathbf{x}) + \mathbf{h}^\top \mathbf{J}^\top \mathbf{f} + \frac{1}{2} \mathbf{h}^\top \mathbf{J}^\top \mathbf{J} \mathbf{h}, \end{aligned} \quad (1.16)$$

kde $\mathbf{f} = \mathbf{f}(\mathbf{x})$ a $\mathbf{J} = \mathbf{J}(\mathbf{x})$. Tzv. *Gauss-Newtonův krok* \mathbf{h}_{gn} minimalizuje $L(\mathbf{h})$,

$$\mathbf{h}_{\text{gn}} = \arg \min_{\mathbf{h}} \{L(\mathbf{h})\}. \quad (1.17)$$

Je zřejmé, že gradient a Hessova matice L jsou tvaru

$$\mathbf{L}'(\mathbf{h}) = \mathbf{J}^\top \mathbf{f} + \mathbf{J}^\top \mathbf{J} \mathbf{h}, \quad \mathbf{L}''(\mathbf{h}) = \mathbf{J}^\top \mathbf{J}. \quad (1.18)$$

Z porovnání s 1.12 plyne, že $\mathbf{L}'(\mathbf{0}) = \mathbf{F}'(\mathbf{x})$. Dále platí, že matice $\mathbf{L}''(\mathbf{h})$ nezávisí na \mathbf{h} . Navíc je také symetrická a pokud má \mathbf{J} všechny řádky lineárně nezávislé, pak $\mathbf{L}''(\mathbf{h})$ je pozitivně definitní. Odtud plyne, že existuje \mathbf{h}_{gn} , které minimalizuje $\mathbf{L}(\mathbf{h})$. Toto obdržíme jako řešení rovnice

$$(\mathbf{J}^\top \mathbf{J}) \mathbf{h}_{\text{gn}} = -\mathbf{J}^\top \mathbf{f}. \quad (1.19)$$

Toto je směr spádu, neboť

$$\mathbf{h}_{\text{gn}}^\top \mathbf{F}'(\mathbf{x}) = \mathbf{h}_{\text{gn}}^\top (\mathbf{J}^\top \mathbf{f}) = -\mathbf{h}_{\text{gn}}^\top (\mathbf{J}^\top \mathbf{J}) \mathbf{h}_{\text{gn}} < 0. \quad (1.20)$$

Pak lze v algoritmu 1 místo \mathbf{h}_d použít \mathbf{h}_{gn} . Příslušný krok algoritmu je pak tvaru

$$\mathbf{x} := \mathbf{x} + \alpha \mathbf{h}_{\text{gn}}; \quad (1.21)$$

kde α lze vypočítat pomocí 1.6, případně ve všech krocích pevně zvolit $\alpha = 1$.

1.2.4 Levenberg–Marquardtův algoritmus

Levenberg a později i Marquardt navrhli použití tzv. *tlumené Gauss-Newtonovy metody*. Krok pro tento algoritmus \mathbf{h}_{lm} je určen vztahem

$$(\mathbf{J}^\top \mathbf{J} + \mu \mathbf{I}) \mathbf{h}_{\text{lm}} = -\mathbf{g}, \quad \text{kde } \mathbf{g} = \mathbf{J}^\top \mathbf{f}, \mu \geq 0. \quad (1.22)$$

Navíc platí označení $\mathbf{f} = \mathbf{f}(\mathbf{x})$ a $\mathbf{J} = \mathbf{J}(\mathbf{x})$. Tlumicí parametr μ má pak několik výhod:

- a) Pro všechna $\mu > 0$ je matice koeficientů pozitivně definitní, tudíž \mathbf{h}_{lm} je směr spádu.
 b) Pro velké hodnoty μ platí

$$\mathbf{h}_{\text{lm}} \simeq -\frac{1}{\mu} \mathbf{g} = -\frac{1}{\mu} \mathbf{F}'(\mathbf{x}),$$

což je krátký krok ve směru největšího spádu. Toto je vhodné pro iterace daleko od řešení.

- c) Pokud je μ velmi malé, pak $\mathbf{h}_{\text{lm}} \simeq \mathbf{h}_{\text{gn}}$. Toto je vhodné pro finální iterace, kdy \mathbf{x} je blízko \mathbf{x}^* .

Tlumící parametr tedy ovlivňuje jak směr, tak i délku kroku. Počáteční volba parametru μ by měla záviset na velikosti prvků v $\mathbf{A}_0 = \mathbf{J}(\mathbf{x}_0)^\top \mathbf{J}(\mathbf{x}_0)$, přesněji

$$\mu_0 = \tau \cdot \max_i \{a_{ii}^{(0)}\}, \quad (1.23)$$

kde τ volí uživatel⁴. V průběhu iterací se velikost μ může měnit. Toto je řízeno poměrem

$$\rho = \frac{F(\mathbf{x}) - F(\mathbf{x} + \mathbf{h}_{\text{lm}})}{L(\mathbf{0}) - L(\mathbf{h}_{\text{lm}})}, \quad (1.24)$$

jehož jmenovatel je odhadnut lineárním modelem 1.16

$$\begin{aligned} L(\mathbf{0}) - L(\mathbf{h}_{\text{lm}}) &= -\mathbf{h}_{\text{lm}}^\top \mathbf{J}^\top \mathbf{f} - \frac{1}{2} \mathbf{h}_{\text{lm}}^\top \mathbf{J}^\top \mathbf{J} \mathbf{h}_{\text{lm}} \\ &= -\frac{1}{2} \mathbf{h}_{\text{lm}}^\top (2\mathbf{g} + (\mathbf{J}^\top \mathbf{J} + \mu \mathbf{I} - \mu \mathbf{I}) \mathbf{h}_{\text{lm}}) \\ &= \frac{1}{2} \mathbf{h}_{\text{lm}}^\top (\mu \mathbf{h}_{\text{lm}} - \mathbf{g}). \end{aligned} \quad (1.25)$$

Platí, že $\mathbf{h}_{\text{lm}}^\top \mathbf{h}_{\text{lm}}$ a $-\mathbf{h}_{\text{lm}}^\top \mathbf{g}$ jsou kladné, tudíž $L(\mathbf{0}) - L(\mathbf{h}_{\text{lm}})$ musí být kladné taktéž.

Velké hodnoty ρ značí, že $L(\mathbf{h}_{\text{lm}})$ vhodně aproximuje $F(\mathbf{x} + \mathbf{h}_{\text{lm}})$ a proto lze zvýšit hodnotu μ , čímž se další Levenberg–Marquardtův krok přiblíží Gauss–Newtonovu kroku. Pokud je naopak hodnota ρ malá (případně záporná), pak $L(\mathbf{h}_{\text{lm}})$ je nevhodnou aproximací a je třeba μ zmenšit. Tímto se délka kroku zmenší a směr se přiblíží směru největšího spádu.

Algoritmus se obvykle ukončuje pomocí tzv. *stop kritéria*, které odpovídá podmínce lokálního minima $\mathbf{F}'(\mathbf{x}^*) = \mathbf{g}(\mathbf{x}^*) = 0$. Používá se tedy podmínka

$$\|\mathbf{g}\|_\infty \leq \varepsilon_1, \quad (1.26)$$

kde ε_1 je malé kladné číslo voleno uživatelem. Další stop kritérium ukončí algoritmus tehdy, pokud se hodnoty \mathbf{x} mění velmi málo

$$\|\mathbf{x}_{\text{new}} - \mathbf{x}\| \leq \varepsilon_2 (\|\mathbf{x}\| + \varepsilon_2). \quad (1.27)$$

Nakonec je třeba přidat kritérium (nutné pro všechny iterační algoritmy), které zabrání uvíznutí v nekonečné smyčce

$$k \geq k_{\text{max}}. \quad (1.28)$$

Stejně tak ε_2 i k_{max} jsou opět volena uživatelem. Podrobný popis výpočtu hodnoty μ a další upřesňující informace jsou k nalezení v [9], str. 26–29.

⁴Algoritmus není příliš citlivý na volbu parametru τ , avšak doporučuje se volit malé hodnoty. Pokud existuje důvod se domnívat, že \mathbf{x}_0 je dobrou aproximací \mathbf{x}^* , pak se volí $\tau = 10^{-6}$. V opačných případech $\tau = 10^{-3}$, případně $\tau = 1$.

2 Dálkový průzkum Země

V této kapitole budou uvedeny základní poznatky o metodách distančního zkoumání zemského povrchu. Jako podklady pro tuto kapitolu byly použity [4], [7] a [13].

2.1 Definice a význam dálkového průzkumu Země

„Dálkový průzkum je věda i umění získávat užitečné informace o objektech, plochách či jevech prostřednictvím dat měřených na zařízení, která s těmito zkoumanými objekty, plochami či jevy nejsou v přímém kontaktu.“ [8]

Pokud se tedy zaměříme konkrétně na *dálkový průzkum Země (DPZ)*, jedná se nejen o zkoumání zemského povrchu či dolních vrstev atmosféry, ale také o zkoumání jevů a procesů, které zde probíhají, na dálku. Podle potřeby se pro tento účel používá jednoho nebo několika intervalů vlnových délek elektromagnetického záření. Pokud se snímá větší množství (několik set) úzce vymezených pásem spektra elektromagnetického záření, mluvíme o tzv. *hyperspektrálním dálkovém průzkumu Země*. Zařízení, která se používají pro zaznamenání intenzity elektromagnetického záření mohou být umístěna na různých nosičích. Nejčastěji se využívají letadla nebo družice. V následujícím textu se budeme zabývat právě leteckým hyperspektrálním dálkovým průzkumem Země.

2.2 Fyzikální podstata dálkového průzkumu Země

Princip dálkového průzkumu Země je založen na poznatku, že objekty či jevy, které se na zemském povrchu nacházejí, určitým charakteristickým způsobem ovlivňují své okolí. Přesněji se zkoumá interakce elektromagnetického záření (tvořené elektromagnetickými vlnami) se zkoumanými objekty. Z Maxwellových rovnic plyne, že elektromagnetická vlna je zvláštním případem elektromagnetického pole, v němž se periodicky mění velikost intenzity elektrického a magnetického pole. Základními charakteristikami jsou *vlnová délka* λ a *frekvence* ν . Mezi frekvencí a vlnovou délkou platí nepřímá úměra

$$c = \lambda\nu, \quad (2.1)$$

kde c je rychlost světla. Jinou teorií vhodnou pro popis interakcí elektromagnetického záření s objekty na zemském povrchu je tzv. *částicová teorie*. Tato předpokládá, že elektromagnetické záření se skládá z jednotlivých částic tzv. fotonů a jejich energie Q souvisí s frekvencí záření ν vztahem

$$Q = h\nu = \frac{hc}{\lambda}, \quad (2.2)$$

kde h je Planckova konstanta.

2.2.1 Radiometrické veličiny

Základní radiometrické veličiny jsou (spolu s jejich fyzikálními rozměry a používanými symboly) uvedeny v tabulce 2.1 a budou dále podrobněji popsány.

veličina	symbol	fyzikální rozměr
zářivá energie	Q	J
zářivý tok	Φ	W
intenzita vyzařování	M	Wm^{-2}
intenzita ozařování	E	Wm^{-2}
zářivost	I	Wsr^{-1}
zář	L	$\text{Wm}^{-2}\text{sr}^{-1}$

Tabulka 2.1: Základní radiometrické veličiny s jejich fyzikálními rozměry a používanými symboly.

Velikost celkové zářivé energie nesené zářením s vlnovými délkami v intervalu $\langle \lambda_1, \lambda_2 \rangle$ je dána integrací

$$Q = \int_{\lambda_1}^{\lambda_2} Q(\lambda) d\lambda. \quad (2.3)$$

Tok záření Φ se definuje podle vztahu

$$\Phi = dQ/dt. \quad (2.4)$$

Je tedy zřejmé, že vyjadřuje rychlost úbytku (přírůstku) zářivé energie.

Velikost energie ozařující danou plochu A (resp. energie, kterou tato plocha do okolního prostoru vyzařuje) se udává pomocí *intenzity ozařování* E (resp. *intenzity vyzařování* M)

$$E = d\Phi/dA, \text{ resp. } M = d\Phi/dA. \quad (2.5)$$

Výše uvedené vztahy vyjadřují celkovou intenzitu veškerého záření, které na plochu A dopadá (nebo je jí vyzařováno). Pro vyjádření zářivého toku v závislosti na prostorovém úhlu se využívá *zářivost*. Ta je definována poměrem

$$I = d\Phi/d\Omega, \quad (2.6)$$

a vyjadřuje zářivý tok vycházející z bodu na ploše A do prostorového úhlu Ω .

Pokud se zářivý tok mění i v závislost na směru, je zapotřebí jeho velikost udávat pomocí *záře* L . Pro záření vyzařované plochou A v zenitním úhlu θ do prostorového úhlu Ω se záře definuje vztahem

$$L = \frac{d^2\Phi}{(dA \cos \theta) d\Omega} = \frac{dI}{dA \cos \theta}. \quad (2.7)$$

Pomocí záře lze vyjádřit ostatní radiometrické veličiny

$$d^2\Phi = L dA \cos \theta d\Omega, \quad (2.8)$$

$$dE = L \cos \theta d\Omega, \quad (2.9)$$

$$dI = L dA \cos \theta. \quad (2.10)$$

Pokud je ve všech směrech θ velikost záře L stejná, jedná se o tzv. *izotropní záření*. V takovémto případě je intenzita ozařování

$$E = \int_M L \cos \theta \, d\Omega = L \int_0^{2\pi} \int_0^{\pi/2} \sin \theta \cos \theta \, d\theta \, d\varphi = \pi L, \quad (2.11)$$

kde M značí polokouli. Jak již bylo uvedeno, v případě izotropního záření je zář ve všech směrech konstantní. Toto ale neplatí pro hodnoty ostatních radiometrických veličin. Pro naměřené hodnoty ve směru $\theta \neq 0$ a ve směru normály k ploše platí

$$\frac{\Phi_\theta}{\Phi_n} = \frac{E_\theta}{E_n} = \frac{I_\theta}{I_n} = \cos \theta. \quad (2.12)$$

Tomuto vztahu se říká *Lambertův* nebo *kosinový zákon*. Popisuje odrazení záření na povrchu, jaký má například sádra nebo filtrační papír. Plochy, které jsou zdroji izotropního záření se označují jako *dokonale difuzní* nebo také *lambertovské*.

2.2.2 Odrazivost a albedo

Sluneční záření dopadající na zemský povrch je zčásti absorbováno, zčásti vedeno do nižších vrstev a zčásti odraženo zpět do atmosféry. Označme intenzitu dopadajícího záření E a intenzitu odraženého záření M . Potom *odrazivost* zavedeme jako poměr

$$\rho = \frac{M}{E}. \quad (2.13)$$

Měření odrazivosti přímo podle definice však přináší značné potíže. Bylo by nutné změřit intenzitu veškerého dopadajícího záření i intenzitu veškerého odraženého záření. Toto ale není vždy zcela možné. Obvykle se tedy měří intenzita odraženého záření, které do přístroje dopadá z prostoru a směru vymezeného zorným polem přístroje. Jak již bylo popsáno, radiometrickou veličinou odpovídající těmto podmínkám měření je zář povrchu. Obdobně lze určit i zář dopadajícího záření. Odrazivost povrchu lze pak početně odvodit.

Obecně je intenzita dopadajícího i odraženého záření silně závislá na směru. Označme θ zenitní úhel a φ azimut směru záření dopadajícího z prostorového úhlu Ω na měřenou plochu A . Obdobně označme úhly θ' , φ' určující úhly odraženého záření měřeného v prostorovém úhlu Ω' . Znázornění zenitního úhlu, azimutu a prostorového úhlu ilustruje obrázek 2.1.

Vztah mezi zenitním úhlem, azimutem a velikostí prostorového úhlu je tedy popsán následovně

$$d\Omega = \frac{dA}{r^2} = \frac{(r \, d\theta) (r \sin \theta \, d\varphi)}{r^2} = \sin \theta \, d\theta \, d\varphi. \quad (2.14)$$


Kompletní popis odrazových vlastností povrchu udává *rozdělovací funkce odrazivosti* (anglicky *bidirectional reflectance distribution function* — *BRDF*)

$$f(\theta, \varphi, \theta', \varphi') = \frac{dL'(\theta', \varphi')}{dE(\theta, \varphi)}, \quad (2.15)$$

kde L' je zář plochy A a E je intenzita ozáření plochy A . Fyzikální rozměr je sr^{-1} .

Diferenciální podoba odrazivosti, tzv. *dvousměrová odrazivost*, je definována jako poměr velikostí intenzit odraženého a dopadajícího záření (vždy pro danou dvojici směrů obou druhů záření)

$$d\rho(\theta, \varphi, \theta', \varphi') = \frac{dL'(\theta', \varphi') \cos \theta' \, d\Omega'}{L(\theta, \varphi) \cos \theta \, d\Omega}. \quad (2.16)$$



Obrázek 2.1: Znáznornění zenitního úhlu θ , azimutu φ a prostorového úhlu Ω .

Vztah mezi dvousměrovou odrazivostí a rozdělovací funkcí lze zapsat ve tvaru

$$d\rho(\theta, \varphi, \theta', \varphi') = f(\theta, \varphi, \theta', \varphi') \cos \theta' d\Omega', \quad (2.17)$$

kde pro Ω' analogicky s 2.14 platí

$$d\Omega' = \sin \theta' d\theta' d\varphi'. \quad (2.18)$$

Pokud se intenzita záření uvnitř prostorového úhlu Ω' nemění, platí

$$\rho(\theta, \varphi, \theta', \varphi') = f(\theta, \varphi, \theta', \varphi') \cos \theta' \Omega'. \quad (2.19)$$

Je zřejmé, že velikost dvousměrové odrazivosti závisí explicitně na úhlu Ω' . Toto je nevýhodné, neboť pak závisí i na použití přístrojové technice.

Prakticky je ale nejsnadnější stanovit *koeficient záře* R (anglicky *bidirectional reflectance factor* — *BRF*). Ten se definuje jako poměr záře zkoumaného objektu L' k záři srovnávacího standardu L'_s při stejné intenzitě dopadajícího záření a stejných geometrických podmínkách

$$R(\theta, \varphi, \theta', \varphi') = \frac{L'(\theta', \varphi')}{L'_s(\theta', \varphi')}. \quad (2.20)$$

Srovnávací standard musí být difuzní a musí mít parametry dokonalého odražeče. Standard má pak rozdělovací funkci odrazivosti

$$f_s = \frac{1}{\pi}. \quad (2.21)$$

Při porovnání vztahů 2.15, 2.20 a využití vlastnosti standardu 2.21 vychází

$$R = \frac{fE}{f_s E} = \pi f. \quad (2.22)$$

Dosazením 2.22 do 2.17 obdržíme vztah mezi koeficientem záře a dvousměrovou odrazivostí ve tvaru

$$d\rho(\theta, \varphi, \theta', \varphi') = \frac{1}{\pi} R(\theta, \varphi, \theta', \varphi') \cos \theta' d\Omega'. \quad (2.23)$$

Po dosazení z 2.18 je

$$d\rho(\theta, \varphi, \theta', \varphi') = \frac{1}{\pi} R(\theta, \varphi, \theta', \varphi') \cos \theta' \sin \theta' d\theta' d\varphi'. \quad (2.24)$$

Odtud integrací příspěvků odraženého záření přes polokouli M obdržíme

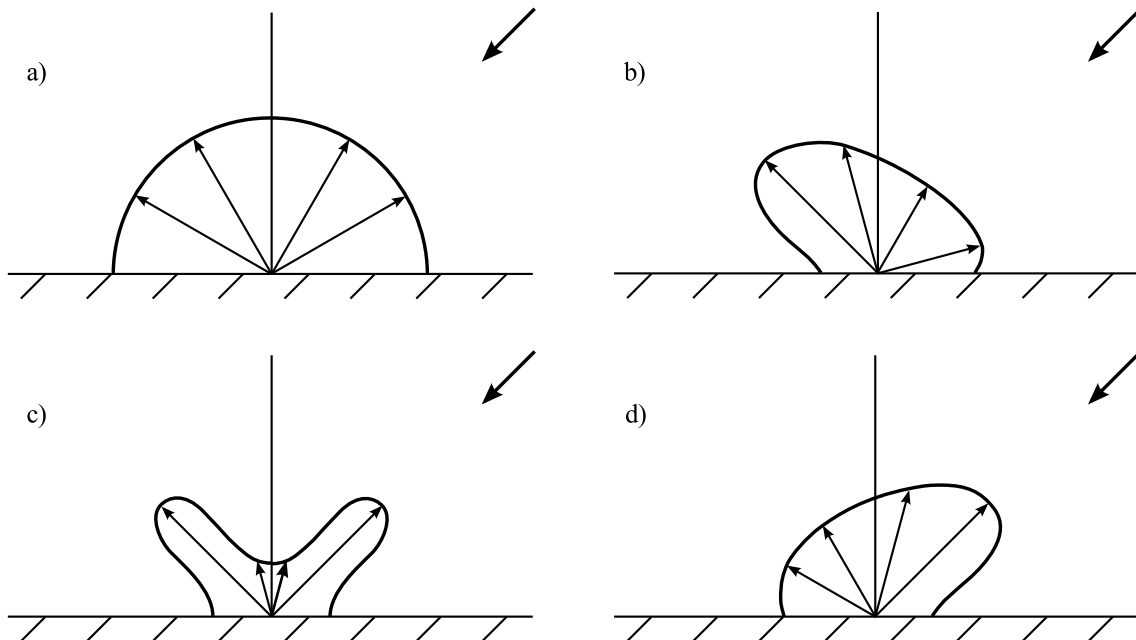
$$\int_M d\rho(\theta, \varphi, \theta', \varphi') = \frac{1}{\pi} \int_0^{2\pi} \int_0^{\frac{\pi}{2}} R(\theta, \varphi, \theta', \varphi') \cos \theta' \sin \theta' d\theta' d\varphi', \quad (2.25)$$

neboli

$$\rho(\theta, \varphi) = R(\theta, \varphi). \quad (2.26)$$

Veličina $\rho(\theta, \varphi)$ se nazývá *směrová odrazivost*. Při integraci směrových odrazivostí přes všechny směry dopadajícího záření obdržíme tzv. *poloprostorovou odrazivost*. Tato odpovídá definici odrazivosti podle 2.13. Pro odrazivost přírodních objektů se používá termín *albedo*.

Závislost koeficientu záře na směru vyjadřuje tzv. *diagram odrazivosti*. V něm se tato závislost vynáší v polárních souřadnicích pro danou polohu zdroje dopadajícího záření a pro daný azimut odrazové roviny (obvykle $\varphi = \pi$ a $\varphi' = 0$). Podle tvaru odrazového diagramu se rozeznávají čtyři hlavní druhy povrchů.



Obrázek 2.2: Diagram odrazivosti pro čtyři hlavní typy povrchu: a) difuzní, b) zrcadlový, c) kombinovaný, d) rýhovaný.

Povrch, který odráží do všech směrů záření stejnoměrně (koeficient záře je konstantní), se nazývá *difuzní*. Takto například odráží ve viditelném spektru písek nebo čerstvý sníh. U tzv. *zrcadlových povrchů* platí, že pro směr $\theta = \theta'$ mají výrazné maximum koeficientu záře. Takto odráží viditelné záření např. led.

Pro diagram odrazivosti *kombinovaného povrchu* platí, že kromě maxima odpovídajícímu zrcadlovému povrchu má ještě protilehlé maximum (v blízkosti úhlu $\theta' = -\theta$). Takovýto diagram je charakteristický pro některé zemědělské plodiny jako je obilí nebo rýže. Posledním typem jsou *rýhované povrchy*. U nich je odrazivost největší ve směru odkud záření na povrch dopadá. Diagramy typické pro jednotlivé druhy povrchů jsou uvedeny na obrázku 2.2.

Při reálném měření záře či intenzity odraženého záření může tedy nerovnost reálného povrchu v krajině výrazně ovlivnit výslednou naměřenou hodnotu. Jak je navíc z diagramů zřejmé, je důležité mít na paměti závislost na azimutálním úhlu směru měření. V průběhu intervalu $0 < \varphi' < \pi/2$ se může velikost koeficientu záře nezanedbatelně měnit.

2.2.3 Charakteristika základních oblastí elektromagnetického spektra využitelných v DPZ


Pro získávání informací o zemském povrchu se v DPZ prostřednictvím měření odraženého nebo vyzářeného záření využívá šest základních oblastí elektromagnetického spektra. Jejich stručná charakteristika je uvedena v následujícím přehledu:

- *ultrafialové záření* (0,1–0,4 μm) — do jisté míry prostupuje do vodního sloupce. Mnoho minerálů vydává v těchto vlnových délkách charakteristické záření. Nevýhodou toho záření je jeho silné pohlcování atmosférou.
- *viditelné záření* (0,4–0,7 μm) — obecně se dále dělí na část *modrého světla* (0,4–0,5 μm), *zeleného světla* (0,5–0,6 μm) a *červeného světla* (0,6–0,7 μm). Je poměrně značně rozptylováno a pohlcováno aerosoly v atmosféře — neprochází oblačností a mlhou. Zdrojem tohoto záření je Slunce — lze jej tedy měřit pouze ve dne. Modrá část spektra může pronikat čistou vodou v oceánu do hloubky 20–30 m.
- *infračervené záření blízké* (0,7–1,4 μm) — je již méně pohlcováno a rozptylováno atmosférou než viditelné záření. Vlnové délky tohoto záření jsou vhodné pro studium vegetace (lesnictví a zemědělství).
- *infračervené záření střední* (1,4–3 μm) — zahrnuje dvě důležité podoblasti se středy přibližně 1,5 a 2,2 μm . První podoblast je vhodná pro rozlišení druhů vegetace, rozpoznání ledu a sněhu, k odlišení oblačnosti a ke studiu zdravotního stavu vegetace. V druhé podoblasti má mnoho minerálů charakteristický absorpční pás.
- *tepelné záření* (3 μm –1 mm) — umožňuje získávání poznatků o tepelné bilanci (používá se např. ke zjišťování povrchové teploty oceánů, lokalizaci lesních požárů a mapování tepelného znečištění).
- *mikrovlnné záření* (1 mm–1 m) — využívá se především u aktivních systémů DPZ (radary). Za vhodných podmínek může pronikat pod zemský povrch. Ze všech uvedených oblastí záření nejméně závisí na podmínkách počasí.


2.2.4 Spektrální chování objektů

Jak již bylo poznamenáno, sluneční záření dopadající na zemský povrch je zčásti absorbováno, zčásti vedeno do nižších vrstev a zčásti odraženo zpět do atmosféry. Množství toho odraženého záření lze charakterizovat již popsanou odrazivostí. Pokud tuto odrazivost měříme v závislosti na vlnové délce, obdržíme tzv. *spektrální odrazivost*.

Pokud vyneseme závislost spektrální odrazivosti na vlnové délce, hovoříme o tzv. *spektrální křivce odrazivosti*. Tato je projevem tzv. *spektrálního chování objektů*. Spektrální křivky odrazivosti mají pro stejnou třídu objektů (voda, vegetace, holá půda, atd.) vždy typický průběh. Toto znázorňuje obrázek 2.3.



Obrázek 2.3: Obecný průběh spektrální odrazivosti a) vody, b) vegetace, c) suché půdy a d) vlhké půdy.



Obrázek 2.4: Spektrální odrazivost: a) zdravé vegetace, b) vegetace brzy po stresu, c) vegetace po jisté době od stresu.

Je zřejmé, že pro každou látku existuje oblast elektromagnetického spektra, ve které se bude nejlépe odlišovat od svého okolí. Např. pro odlišení listnatých a jehličnatých stromů se nejvíce hodí oblast infračerveného záření. Zde jsou jehličnaté stromy charakterizovány nižšími hodnotami odrazivosti než stromy listnaté. Naopak ve viditelné části spektra je spektrální chování jehličnatých a listnatých stromů téměř identické.

Pomocí spektrální křivky odrazivosti lze u vegetace zjišťovat její zdravotní stav. Toto ukazuje obrázek 2.4. Pokud je vegetace vystavena stresu, je porušen její růst a klesá u ní aktivita chlorofylu. Tím pádem se výrazně sníží odrazivost v infračervené části spektra a naopak se zvýší odrazivost v modré a červené části viditelného spektra — toto má za důsledek žloutnutí rostlin. Tohoto jevu se využívá právě při mapování zdravotního stavu vegetace a lze tak zaznamenat změny, které by byly pouhým okem zjistitelné až po delší době.

3 Zpracovávaná data

Hlavním objektem této práce jsou reálná hyperspektrální data naměřená Centrem výzkumu globální změny AV ČR (dále jen CVGZ). Tato kapitola se zabývá popisem struktury těchto dat, možnostmi jejich vizualizace, způsobem snímání a korekcemi, které byly na uvedených datech provedeny.

3.1 Způsob snímání

Dne 25. 5. 2011 bylo nad blízkým okolím obce Dehtáře na Vysočině pořízeno několik letových hyperspektrálních obrazových linií. K získání dat byl použit letecký hyperspektrální systém AISA Eagle, vyvinutý firmou Spectral Imaging Ltd. Typ tohoto systému se díky způsobu snímání nazývá *pushbroom* (viz. obrázek 3.1) a skládá se z kompaktní hlavy obsahující hyperspektrální senzor, GPS/INS jednotky, akvizičního PC a senzoru snímajícího dopadající ozáření (FODIS).


Pomocí inerciální navigační jednotky GPS/INS je monitorována aktuální pozice a poloha letadla (ve třech osách). Dále jsou se signálem GPS/INS synchronizována data, která jsou pořizována hyperspektrálním senzorem a nahrávána do akvizičního PC. V tabulce 3.1 jsou uvedeny technické informace snímače, v tabulce 3.2 pak technické informace k nasnímaným datům.

Spektrální rozsah	400–1000 nm
Spektrálních pixelů	244
Spektrální rozlišení	max. 2,9 nm
Senzor	CCD
Výstup	12 bitů
FODIS	Senzor, který snímá dopadající záření

Tabulka 3.1: *Technické informace o snímači.*

Senzor	AISA Eagle — SN100014
Nosič	Cesna (Argus-Geo System)
Letová rychlost	50 m/s
Spektrální rozlišení	2,16–2,36 nm
FPS (frekvence skenování)	20
Prostorové rozlišení	2,5 m
Šířka snímané linie	1192,5 m
Výška letu nad povrchem	3016 m
Objektiv	23 mm
Počet pixelů v příčném směru	477
Počet spektrálních pásem	260

Tabulka 3.2: *Technické informace k nasnímaným datům.*



Obrázek 3.1: Způsob získávání dat pomocí pushbroom systému.

3.2 Význam dat

Pomocí uvedeného senzoru byla tedy nad daným územím snímána data, která představují spektrální odrazivost.

Pro uchování naměřených dat je použit binární soubor se strukturou, kterou chápeme jako třírozměrné pole. První rozměr reprezentuje řádky (anglicky *lines*). Druhý rozměr pak reprezentuje sloupce a třetí spektrální pásma (anglicky *bands*). Naměřená data jsou tedy uchovávána v trojrozměrné matici $(a_{i,j,k})$, kde $a_{i,j}$ jsou jednotlivé pixely a index k určuje příslušné spektrální pásmo. Jak je uvedeno v tabulce 3.2, každý z pixelů reprezentuje plochu $2,5\text{ m} \times 2,5\text{ m}$ na zemském povrchu a každá hodnota v binárním souboru tudíž obsahuje informaci o naměřené odrazivosti pro danou plochu zemského povrchu a dané spektrální pásmo.

Na pořadí jednotlivých záznamů v datech záleží a podle toho se rozlišuje několik způsobů uspořádání dat v binárním souboru. Pokud R značí počet řádků, S počet sloupců a T počet spektrálních pásem, potom data uspořádaná způsobem *BSQ* (Band-Sequential, neboli souvisle po spektrálních pásmech) mají dimenzi $R \times S \times T$. Naopak data uspořádaná způsobem *BIL* (Band-Interleaved-by-Line, neboli spektrální pásma prokládaná po řádcích) mají dimenzi $R \times T \times S$. Dále se ještě používá způsob *BIP* (Band-Interleaved-by-Pixel, neboli spektrální pásma prokládaná po pixelech), kdy data mají dimenzi $S \times R \times T$.


Ke každému binárnímu souboru je pak přiložen tzv. hlavičkový soubor, ve kterém je uvedený konkrétní počet řádků a sloupců, počet spektrálních pásem, vlnová délka středu a šířka těchto pásem, způsob uspořádání dat, použitý datový typ a případně další informace.

Ve výsledku mají data rozměr počet řádků \times počet sloupců \times počet spektrálních pásem. Pokud každá datová položka zabírá 16 bitů (je použit datový typ unsigned integer), pak například datový soubor o rozměrech $3537 \times 477 \times 260$ zabírá v paměti $3537 \cdot 477 \cdot 260 \cdot 16 = 7018539840$ bitů $\doteq 836,7$ MB.

Samotné hodnoty spektrální odrazivosti jsou čísla v rozsahu 0–1, které udávají procentuální odrazivost. Ale pro výhodnější využití celého rozsahu datového typu unsigned integer jsou tyto hodnoty v datovém souboru násobeny koeficientem 10000.

3.3 Re prezentace dat

Samotná číselná reprezentace (sice uspořádaná do třírozměrného pole) neposkytuje pro uživatele dostatečně komplexní vzhled a představu o chování a charakteru naměřených dat. Je tedy často potřeba tato data vhodně reprezentovat (nejčastěji graficky). Pokud pro určitou oblast snímaného území vyneseme do grafu hodnoty naměřené odrazivosti ve všech spektrálních pásmech, potom jejich proložením (či prostým spojením) obdržíme již dříve zmíněnou spektrální křivku odrazivosti. Tato nám dává představu o tom, co se na vybraném místě vyskytuje a jaké jsou vlastnosti tohoto pokryvu. Obrázek 3.2 znázorňuje naměřené spektrální odrazivosti pro vybraný pixel z datového souboru. Jen pro upřesnění je třeba uvést, že při nastavení spektrálního rozsahu AISA snímače došlo k chybě, a proto jsou spektrální odrazivosti naměřené v prvních 25 spektrálních pásmech chybné. Toto ale nezpůsobuje žádný problém, neboť se budou data zpracovávat po jednotlivých spektrálních pásmech a tudíž je možné daná pásma vynechat.



Obrázek 3.2: Naměřené spektrální odrazivosti pro vybraný pixel z datového souboru.

Dalším způsobem může být přímá vizualizace nasnímaných dat. Jak je vidět v tabulce 3.1, vlnové délky elektromagnetického záření použité pro snímání dat zahrnují i viditelné záření. Pokud tedy použijeme hodnoty z vhodných spektrálních pásem pro jednotlivé složky *Red*, *Green* a *Blue*, můžeme data jednoduše vizualizovat jako klasickou digitální fotografii. Na obrázku 3.3 lze vidět, jak může takováto grafická reprezentace vypadat, pokud jsou pro barevné složky použity následující vlnové délky: *Red* — 0,6391 μm , *Green* — 0,5490 μm , *Blue* — 0,4595 μm (nutno poznamenat, že je vhodné upravit jas).



Obrázek 3.3: *Přímá vizualizace výřezu dat.*

3.4 Předzpracování dat

Při snímání dat metodami dálkového průzkumu Země působí na výsledný záznam řada vlivů, které ve výsledku zhoršují jeho kvalitu a odchyľují jej od skutečnosti. Tyto nepřesnosti v záznamu může způsobovat nedokonalost měřicího přístroje, vliv atmosféry či samotná podstata dálkového průzkumu.

Pro další použití nasnímaných dat je tedy nutné odstranit, či alespoň potlačit tyto chyby a nepřesnosti. K tomuto se např. používají tzv. *radiometrické* korekce, které upravují naměřené hodnoty záznamu tak, aby co nejvíce odpovídaly skutečným vlastnostem zkoumaných objektů. Dále se provádí korekce *atmosférické*, které minimalizují vliv atmosféry při měření odrazových či zářivých vlastností a tím se získají absolutní hodnoty naměřeného spektrálního chování pro kvantifikaci jejich vlastností. Obě tyto korekce budou dále popsány.

3.4.1 Radiometrické korekce

Jak již bylo zmíněno, cílem radiometrických korekcí je upravení nasnímaných dat tak, aby co nejvíce odpovídaly skutečnosti. Pokud je cílem zkoumání časová změna daného objektu, pak nasnímaná data z různých částí roku mohou mít navzájem velmi rozdílné hodnoty. Toto je způsobeno rozdílnou výškou Slunce v daných částech roku a různými

podmínkami pro rozptyl a pohlcování měřeného záření. Informace o pozici Slunce jsou pro každé snímání známy, tudíž lze obraz příslušně upravit.

Většina digitálně nasnímaných dat obsahuje chyby do jisté míry náhodné povahy. Tyto mohou být způsobeny chybou v senzoru, jeho špatnou kalibrací či chybou při přenosu signálu. Jako první byla provedena úprava dat pomocí tzv. *dark frame*. Pomocí zprůměrování série snímků zatemněného senzoru (nasnímaných za podmínek stejných jako při snímání dat) se vytvoří obraz, který se odečte od naměřených dat. Tímto se minimalizují chyby způsobené teplotou a délkou expozice.

Dále byla provedena korekce pomocí programu CaliGeo Ver. 4.9.12. (Spectral Imaging Ltd). Zde se data kalibrovala na radiometrické hodnoty.

3.4.2 Atmosférické korekce

Atmosféra jako hmotné prostředí způsobuje nepřesnosti nasnímaných dat převážně procesy pohlcování a rozptylu na vodních kapičkách, plynech, aerosolech a pevných částicích. Tyto procesy jsou ovlivňovány několika faktory. Převážně však vlnovou délkou měřeného záření. Jak již bylo uvedeno, toto se projevuje nejvíce v oblasti viditelného záření.

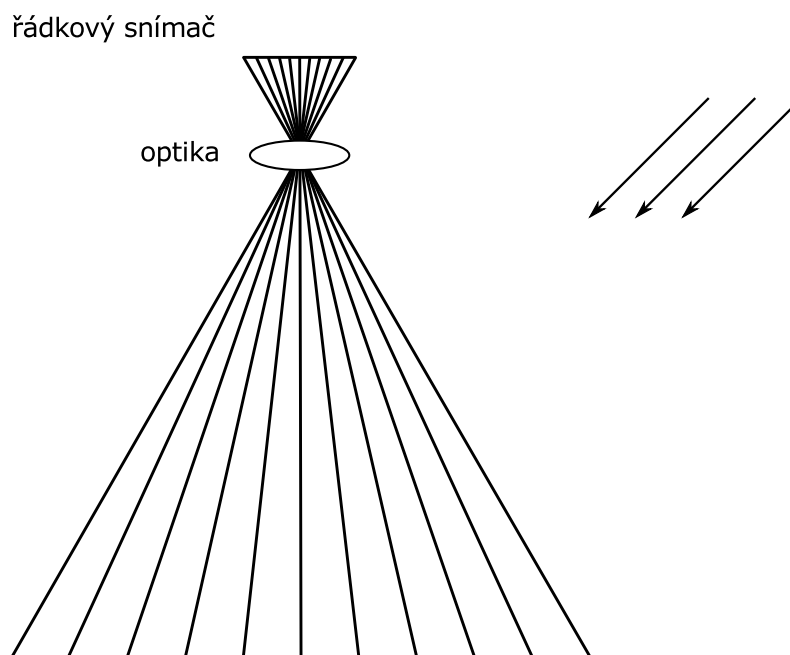
U dat použitých pro tuto práci byly proto v programu ATCOR-4 Ver. 4.1 (ReSe Application Schlaepfer) spočítány atmosférické korekce. Výsledná atmosféricky korigovaná data jsou vyjádřena v hodnotách reflektance.

4 Nadir normalizace

Dalším krokem předzpracování dat je tzv. *nadir normalizace*. Pojmem nadir (též *podnožník*) se označuje bod, který leží přímo pod pozorovatelem (opak nadiru je zenit). Cílem je upravit data tak, aby odpovídala způsobu snímání, při kterém by byl každý bod na zemském povrchu letové linie snímán z pozice přímo nad tímto bodem. Jedná se tedy o normalizaci dat vzhledem k úhlu snímání, což je problematika, která je hlavním tématem této práce. Proto se tato kapitola zabývá popisem a definicí problému, různými přístupy a metodami jeho řešení. Jako podklady pro tuto kapitulu byly použity [1], [4], [5], [7], [10], [11], [12] a [13].

4.1 Popis problému

Předešlá kapitola se zabývala zpracovávanými daty — bylo zde uvedeno, že pomocí senzoru byla nasnímana data představující spektrální odrazivost. Avšak je třeba zdůraznit poznatky z 2.2.2, že naměřené spektrální odrazivosti závisí na azimutálním a zenitním úhlu snímání. Jak již bylo vidět na obrázku 3.1, úhel snímání se napříč snímanou linií mění. Toto ještě přesněji zobrazuje obrázek 4.1, kde je patrný rozdíl mezi úhly snímání na krajích a středu letové linie. Normalizace dat vzhledem k úhlu snímání se tedy snaží eliminovat vliv azimutálního a zenitního úhlu snímání, který popisuje rozdělovací funkce odrazivosti (dále se z důvodu zkrácení a také v důsledku používané terminologie bude používat pouze zkratka *BRDF*). Je třeba také připomenout, že BRDF je pro každý materiál zcela odlišná. Proto je třeba při nadir normalizaci přistupovat ke každému typu pokryvu samostatně.



Obrázek 4.1: Znárodnění rozdílu úhlu snímání napříč snímanou linií.

Je tedy zřejmé, že se ve výsledku u naměřených dat bez nadir normalizace vyskytuje závislost na snímacím úhlu napříč letovou linií. To se může projevit tím, že jsou hodnoty naměřené spektrální odrazivosti pro stejné pokryvy zemského povrchu směrem ke krajům nasnímané linie posunuty o určitou konstantu (při přímé vizualizaci jsou pixely směrem k jednomu kraji „tmavší“ a k druhému „světlejší“) — jedná se o tzv. *BRDF efekt*. Pokud se tedy nasnímá několik letových linií vedle sebe, a dále by se tato data bez nadir normalizace skládala do jediného datového souboru popisujícího větší plochu na zemském povrchu, byl by v hodnotách naměřených spektrálních odrazivostí stejných objektů na hranici dvou letových linií skok. Dá se proto říci, že směrem ke krajům napříč letovou linií dochází ke zkreslení nasnímaných dat oproti skutečnosti. Z těchto důvodů je nadir normalizace důležitou součástí předzpracování nasnímaných dat.

4.2 Způsob řešení

Při nadir normalizaci je třeba přistupovat k datům po jednotlivých vlnových délkách a samotnou normalizaci provádět pro jednotlivé typy pokryvu zvlášť. Datový soubor je tedy nutné nejdříve rozdělit na vhodný počet nepřekrývajících se oblastí (tzv. *tříd*), které pokrývají celý datový soubor. Každá třída pak obsahuje pixely, které patří do určitého typu pokryvu se stejnými, nebo alespoň podobnými vlastnostmi.

Pro tyto třídy se pak vypočítá vhodná charakteristika, pomocí které se určí příslušný BRDF efekt. Jeho vliv je třeba minimalizovat — to se provádí pomocí BRDF modelů. Pomocí nelineárních metod nejmenších čtverců se vypočítané charakteristiky proloží právě tímto modelem, ze kterého se odvodí příslušná normalizační funkce. Pomocí této se pak daný datový soubor normalizuje.

Následující části textu se budou podrobněji věnovat jednotlivým bodům postupu a různým přístupům k nadir normalizaci.

4.2.1 Klasifikace tříd pokryvu

Metody klasifikace digitálního obrazu se dělí na *řízené* a *neřízené*. U řízené klasifikace nejprve vybere uživatel tzv. *trénovací plochy*, které jsou vzorem pro jednotlivé třídy. Na těchto plochách se pomocí vhodného algoritmu vypočítá určité pravidlo, pomocí kterého pak proběhne samotná klasifikace. Naopak neřízená klasifikace je založena na principech shlukové analýzy — data jsou statisticky rozdělena do *shluků*. Následně je nutné přiřadit jednotlivým shlukům obsahový význam.

Na rozdíl od klasického digitálního obrazu (který má pouze tři barevné složky), obsahují zde používaná hyperspektrální obrazová data naměřené spektrální odrazivosti pro 260 různých spektrálních pásem. Navíc je nutno připomenout, že datové soubory nabývají velikých rozměrů (až 3537×477 pixelů). Z těchto důvodů je tedy nutné zvolit vhodný algoritmus klasifikace. Nejvhodnější je použití metod řízené klasifikace — na mnohonásobně menší trénovací ploše se určí klasifikační pravidlo a samotná výsledná klasifikace pak proběhne relativně rychle. Jednou z vhodných metod je *Maximum Likelihood Classification*, neboli klasifikace pomocí maximální věrohodnosti. Tato metoda je založena na předpokladu, že rozdělení bodů tvořících jednu třídu tréninkových dat má Gaussovo rozdělení. Pomocí určitých parametrů pak lze spočítat statistická pravděpodobnost dané hodnoty pixelu jako člena vybrané třídy.

Další vhodnou metodou je *Neural Net Classification*, neboli klasifikace pomocí neuronových sítí. Tato klasifikační metoda je implementovaná v ENVI Software-Image Analysis Software, který používají v CVGZ a pomocí kterého budou klasifikována data v praktické části této práce. Z tohoto důvodu bude tato metoda dále podrobněji popsána.

Neuronové sítě

Základem matematického modelu neuronových sítí je tzv. *formální neuron*. Jeho schéma je zobrazeno na obrázku 4.2. Tento neuron Y má obecně n reálných vstupů, které určují vstupní vektor $\mathbf{x} = (x_1, \dots, x_n)$. Každý vstup je ohodnocen reálnou *synaptickou vahou*, které dohromady tvoří vektor $\mathbf{w} = (w_1, \dots, w_n)$. Vážená suma vstupních hodnot y' představuje *vnitřní potenciál neuronu Y* :

$$y' = \sum_{i=1}^n w_i x_i.$$


Hodnota vnitřního potenciálu y' po dosažení hodnoty *fixního prahu* θ indukuje výstup y neuronu Y . Nárůst výstupní hodnoty y (aktivace) je dán tzv. *aktivační funkcí* $f(y')$. Tato může být různých typů, nejjednodušším typem je ale *ostrá nelinearita*, která má pro neuron Y tvar:

$$y = f(y') = \begin{cases} 1, & \text{pokud } y' \geq \theta, \\ 0, & \text{pokud } y' < \theta. \end{cases}$$

Neuronová síť se pak skládá z formálních neuronů, které jsou vzájemně zapojeny. Výstup jednoho neuronu je vstupem do (obecně více) dalších neuronů. Počet neuronů a jejich vzájemné propojení určuje topologii neuronové sítě. V síti se z hlediska využití rozlišují vstupní, pracovní (skryté) a výstupní neurony. Struktura neuronové sítě je zobrazena na obrázku 4.3. Samotné zpracování informace v síti probíhá změnou stavů neuronů ležících na cestě mezi vstupními a výstupními neurony. Stav neuronové sítě je určen stavy všech neuronů a synaptické váhy všech spojů představují konfiguraci neuronové sítě. Samotná neuronová síť se v průběhu času vyvíjí — mění se stav neuronů a adaptují se váhy. Proto se dynamika neuronové sítě dělí na tři režimy práce: *organizační* (změna topologie), *aktivní* (změna stavu) a *adaptivní* (změna konfigurace). Tyto dynamiky jsou zadány počátečním stavem a pravidlem, které určuje vývoj příslušné charakteristiky sítě v čase.

Při aplikaci neuronových sítí se nejčastěji používá tzv. *algoritmus zpětného šíření chyby* (*backpropagation*). Tento obsahuje tři části: dopředné (feedforward) šíření vstupního signálu tréninkového vzoru, zpětné šíření chyby a aktualizace váhových hodnot na spojech. Při dopředném šíření signálu obdrží každý neuron ve vstupní vrstvě signál, který zprostředkuje ke všem neuronům ve skryté vrstvě. Zde je vypočtena aktivace a poslána všem neuronům ve výstupní vrstvě. Zde každý výstupní neuron vypočítá také svou aktivaci — ta odpovídá jeho skutečnému výstupu po předložení vstupního vzoru. Důležitou otázkou ale je, jakým způsobem jsou stanoveny synaptické váhy vedoucí ke korektní odezvě na vstupní signál. Toto je spojeno s pojmem *učení* (*adaptace*) neuronové sítě. Další otázkou je míra *generalizace* (*zobecnění*) — do jaké míry lze z naučeného reagovat na jevy, které nebyly součástí učení, ale lze je z naučeného nějak odvodit.

Pro adaptaci neuronové sítě je zapotřebí trénovací množina. Metoda, která umožňuje adaptaci neuronové sítě nad danou trénovací množinou se nazývá *metoda zpětného šíření chyby* (*backpropagation*). Zde probíhá adaptace směrem od vyšších vrstev k vrstvám nižším. Srovnávají se vypočtené aktivace y_k s definovanými vstupními hodnotami pro



Obrázek 4.2: Schéma formálního neuronu.

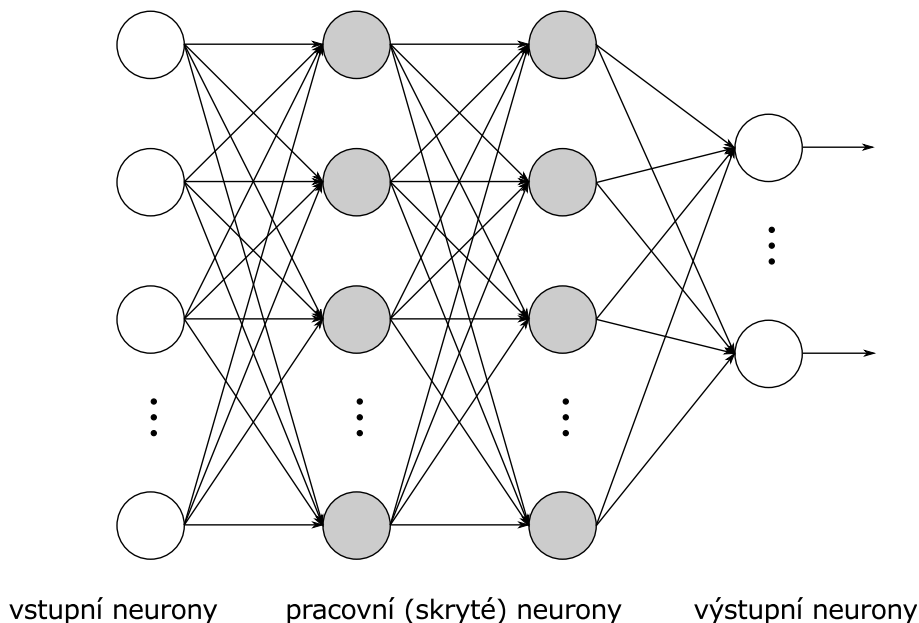
každý neuron ve výstupní vrstvě a pro každý tréninkový vzor. Podle tohoto srovnání se vypočítá chyba neuronové sítě a k ní faktor δ_k . Tento faktor odpovídá části chyby, která se šíří zpětně z neuronu Y_k ke všem neuronům předcházející vrstvy, se kterými měl tento neuron definované spojení. Pomocí tohoto se postupně upravují synaptické váhy a hodnoty prahu. Aktivační funkce použitá pro neuronové sítě s adaptační metodou backpropagation musí být spojitá, diferencovatelná a monotónně neklesající, proto se nejčastěji používá standardní sigmoida nebo hyperbolický tangens.

Kromě samotné minimalizace chybové funkce je dalším problémem použitá topologie neuronové sítě pro řešení konkrétního problému. Obecně se používá vícevrstvá topologie s jednou či více vnitřními vrstvami, kde se očekává, že adaptační algoritmus backpropagation zobecní dané vztahy z tréninkové množiny ve vahách jednotlivých spojů mezi neurony. Ale i tak je třeba vhodně volit počty neuronů ve vnitřních vrstvách. Pokud je síť příliš malá, adaptace se zastaví v mělkém lokálním minimu a je nutno topologii doplnit o další vnitřní neurony. Naopak bohatá architektura sice umožní nalézt globální minimum chybové funkce, avšak špatně generalizuje — příliš zobecní tréninkové vzory včetně jejich nepřesností a chyb a pro nenaučené vzory dává chybné výsledky.

Mnohdy se také kombinují různé typy neuronových sítí — například je výsledná síť složená ze dvou částí. První část je například neuronová síť typu *SOM* (*Self-organizing Maps*, neboli *samoorganizující mapy*), která využívá tzv. *soutěžní strategii učení* — výstupní neurony sítě soutěží o to, který z nich bude aktivní. Po určitém čase zůstává aktivní pouze jeden neuron. Vstupy jsou pak tříděny do skupin dle „vítězného“ neuronu. K této síti je připojena výše popsaná část s adaptačním algoritmem backpropagation. Ve výsledku se pak díky samoorganizující části částečně vyřeší problém ohledně počtu neuronů ve vnitřních vrstvách.

V konečném výsledku se tedy neuronová síť pomocí trénovací množiny adaptuje a lze pak s její pomocí klasifikovat celý datový soubor. Jako podklad pro tuto část byl použit [14], kde lze také nalézt různé modifikace, přesnější definice a celkově další informace o neuronových sítích.

Výsledkem klasifikace je výstupní datový soubor, který může mít různé uspořádání. Jednou z možností je klasické dvourozměrné uspořádání, kde hodnota uložená v každém

Obrázek 4.3: *Struktura neuronové sítě.*


pixelu reprezentuje přiřazenou třídu. Další možností je třírozměrná matice, kde třetí rozměr reprezentuje jednotlivé třídy. Každý pixel pak pro jednotlivou třídu nabývá hodnoty 0 v případě že nebyl klasifikován do této třídy, nebo naopak 1 pokud byl klasifikován do dané třídy. Je zřejmé, že každý pixel může patřit pouze do jediné třídy, tudíž hodnota 1 může být uložena pro každý pixel pouze na jediné pozici třetího rozměru. Případně lze výsledek reprezentovat graficky, což znázorňuje obrázek 4.4, na kterém je zobrazena klasifikace obrázku 3.3. Zde každá barva reprezentuje určitou třídu.

Protože probíhá klasifikace pixel po pixelu, často se ve větší homogenní ploše vyskytují různé pixely z jiných tříd. Toto může například vypadat tak, že je několik izolovaných pixelů uprostřed třídy charakterizující pole klasifikováno do třídy charakterizující les. Pro další zpracování je tedy vhodné data *vyhladit*. Toto se nejčastěji provádí pomocí postklasifikačního filtru založeného na logickém operátoru. Pohyblivé okno (o určité velikosti určené uživatelem) postupuje přes klasifikovaná data, kde se vždy určí majoritní třída. Pokud střední pixel pohyblivého okna náleží do jiné než majoritní třídy, přepíše se hodnota tohoto pixelu na majoritní. Použití tohoto postklasifikačního filtru na klasifikovaná data uvedená v obrázku 4.4 znázorňuje obrázek 4.5. Často se tento filtr modifikuje pomocí váhových funkcí pro jednotlivé pixely pohyblivého okna.

4.2.2 Statistická charakteristika sloupců

Nyní předpokládejme, že podél celé letové linie se BRDF efekt napříč touto linií pro jednotlivé typy pokryvu nemění. Tento předpoklad je přirozený, neboť při snímání dat letí letadlo nesoucí snímací zařízení rovně (po celou dobu letu udržuje daný směr). Navíc je při snímání jedné letové linie Slunce na stejné pozici (a navíc dostatečně daleko). Avšak pokud je snímáný povrch členitý, potom uvedený předpoklad neplatí (tímto problémem se tato práce nebude zabývat).

Dalším krokem po klasifikaci datového souboru tedy bude určení BRDF efektu pro každý pokryv napříč letovou linií. Východiskem je určit vhodnou statistickou charakte-




Obrázek 4.4: *Přímá vizualizace výstupu klasifikace — každá barva odpovídá určité třídě.*

ristiku pro pixely každého typu pokryvu z jednotlivých sloupců (za předpokladu, že ve sloupcích jsou hodnoty snímané ve směru letu) datového souboru. Toto je navíc třeba určit pro všechna spektrální pásma datového souboru. Pomocí těchto charakteristik pak bude možné pro daný pokryv a dané spektrální pásmo zjistit požadovaný BRDF efekt.

K tomuto je vhodné použít některou z charakteristik polohy statistického souboru uvedených v kapitole 1.1. Jednotlivé statistické soubory budou tvořit naměřené hodnoty spektrální odrazivosti pro jednotlivé spektrální pásma pixelů z daného sloupce a patřících do určité klasifikační třídy. Důležité je zvolit vhodnou (nejlépe robustní) charakteristiku polohy. Jak je uvedeno v poznámce 3, robustní charakteristikou je medián. Požadavek robustnosti je zde důležitý, neboť výslednou charakteristiku neovlivní extrémní hodnoty (které se zde mohou vyskytovat přirozeně, či chybou — např. chybně klasifikovaný pixel).

Výsledný BRDF efekt pro jednotlivé třídy pokryvu lze znázornit graficky — do grafu se vynesou vypočítané charakteristiky pro hodnoty pixelů z jednotlivých sloupců a daných tříd pokryvu (opět pro každé spektrální pásmo zvlášť). Vodorovná osa tedy reprezentuje jednotlivé sloupce a svislá osa pak vypočítané charakteristiky. Takovýto graf znázorňuje obrázek 4.6. Avšak je nyní důležité, aby byla data správně klasifikována do tříd (převážně je důležité, aby bylo použito správného počtu tříd). V grafu se pak může vyskytnout oblast, kde se BRDF efekt chová zdánlivě odlišně. Pokud se tedy data dané třídy znovu klasifikují (např. pomocí vhodné metody neřízené klasifikace) do vhodného počtu podtříd (a pro každou se opět spočítají charakteristiky), pak se zmíněný problém odstraní.



Obrázek 4.5: Přímá vizualizace výstupu postklasifikačního filtru aplikovaného na klasifikovaná data.

4.2.3 BRDF modely


Rozdělovací funkce odrazivosti (anglicky *bidirectional reflectance distribution function* — *BRDF*) byla již podrobně popsána v kapitole 2.2.2. Nyní však bude lepší popsat směrovou odrazivost pomocí vhodné funkce s malým počtem parametrů — tzv. *BRDF (parametrického) modelu*. V literatuře jsou tyto modely nejčastěji přímo doporučovány pro dané typy povrchů a pro různé metody využití. Většinou jsou označovány jako empirické nebo semiempirické statistické modely. Dalším cílem tedy bude proložit vypočítané charakteristiky vhodným BRDF modelem a pomocí tohoto následně provést normalizaci. Některé BRDF modely budou proto dále popsány (viz. [1], [10], [12] a [13]).

Minneartův model

Jedná o jeden ze starších modelů, který se často užíval v planetární astronomii. Tento model je tvaru


$$R(\theta_i, \theta_v) = \frac{\rho_0}{(\mu_i \mu_v)^{1-k}} = \frac{\rho_0}{(\cos \theta_i \cos \theta_v)^{1-k}}, \quad (4.1)$$

kde ρ_0 je koeficient a k je bezrozměrný parametr od 0 do 1. Pro $k = 1$ se jedná o Lambertův zákon. Pro tmavé povrchy je hodnota k okolo 0,5. Čím světlejší je povrch, tím k narůstá. Dále jsou v modelu použity θ_i a θ_v , což jsou zenitní úhel Slunce a zenitní pozorovací úhel.



Obrázek 4.6: Vypočítané charakteristiky (v tomto případě medián) všech sloupců pro jednotlivé třídy pokryvu — jednotlivé třídy barevně rozlišeny.

Tyto znázorňuje obrázek 4.7. Pokud θ_i , nebo θ_v roste (zmenšují se μ), potom odrazivost stoupá. Nevýhodou je, že tento model nezahrnuje závislost na azimutu — tudíž se nehodí na popis směrové odrazivosti pro strukturované povrchy (např. les).



Obrázek 4.7: Znázornění zenitního úhlu Slunce θ_i a zenitního pozorovacího úhlu θ_v .

Lommel-Seeligerův model

Tento model se taktéž využíval často v planetární astronomii. Je tvaru

$$R(\theta_i, \theta_v) = \frac{2\rho_0}{\mu_v + \mu_i}, \quad (4.2)$$

kde všechny proměnné mají stejný význam jako u předcházejícího modelu. Je mu velmi podobný a taktéž nezahrnuje závislost na azimutu. Naopak dobře popisuje směrovou odrazivost tmavých povrchů. Pro pevný zenitní úhel Slunce platí, že odrazivost roste se zvětšujícím se zenitním pozorovacím úhlem (zmenšujícím se μ_v). Toto stejné platí pro pevný zenitní pozorovací úhel a zvětšující se zenitní úhel Slunce.

Rahmanův model

Pro popis kombinace odrazivosti v atmosféře a na zemském povrchu byl navržen následující parametrický model

$$R(\theta_i, \theta_v, \phi) = \rho_0 M(\theta_i, \theta_v) F(\theta_i, \theta_v, \phi) [1 + G(\theta_i, \theta_v, \phi)], \quad (4.3)$$

kde

$$M(\theta_i, \theta_v) = \frac{\cos^{k-1} \theta_v \cos^{k-1} \theta_i}{(\cos \theta_i + \cos \theta_v)^{1-k}}, \quad (4.4)$$

$$F(\theta_i, \theta_v, \phi) = \frac{1 - b^2}{[1 + b^2 - 2b \cos(\pi - g)]^{3/2}}, \quad (4.5)$$

$$\cos g = \cos \theta_i \cos \theta_v + \sin \theta_i \sin \theta_v \cos \phi, \quad (4.6)$$

$$G(\theta_i, \theta_v, \phi) = \frac{1 - a}{1 + \sqrt{\operatorname{tg}^2 \theta_i + \operatorname{tg}^2 \theta_v - 2 \operatorname{tg} \theta_i \operatorname{tg} \theta_v \cos \phi}}. \quad (4.7)$$

Přičemž ρ_0 , a , b a k jsou koeficienty, θ_i a θ_v mají stejný význam jako u předcházejících modelů a ϕ je relativní azimutální úhel mezi směrem slunečního záření a směrem pozorování. Funkce M je kombinací Minneartova a Lommel-Seeligerova modelu. Funkce F modeluje rozptyl aerosolu a G popisuje tzv. *hotspot efekt* BRDF (vysoká špička odrazivosti ve směru přímého odrazu).

Roujeanův model

Tento model patří mezi tzv. *Kernel functions* (neboli jádrové funkce). Skládá z více částí (jader) — první popisuje odrazivost povrchových objektů. Povrchové objekty jsou zde modelovány jako výběžky, které odráží záření podle Lambertova zákona a navíc mohou vrhat stín. Tyto reprezentují nepravidelnost a nerovnost holého povrchu. Toto tzv. geometrické jádro (K_{geo}) se tedy odvodilo pomocí velkého počtu shodných výběžků, které byly charakteristické svoji délkou, šířkou a výškou.

Druhé jádro (K_{vol}) popisuje rozptyl na nekonečném povrchu. Toto se reprezentuje jako množina náhodně rozmístěných hran, které absorbují a rozptylují záření. Tento nekonečný povrch pak může být půda či vegetační pokryv. Jak autoři uvádí v [12], lze tento model vyjádřit ve tvaru

$$R(\theta_i, \theta_v, \phi) = \alpha_0 + \alpha_1 K_{vol}(\theta_i, \theta_v, \phi) + \alpha_2 K_{geo}(\theta_i, \theta_v, \phi), \quad (4.8)$$

kde α_1 , α_2 a α_3 jsou koeficienty a θ_i , θ_v a ϕ mají stejný význam jako u předcházejících modelů. Jádru popisující rozptyl je určeno vztahem

$$K_{vol}(\theta_i, \theta_v, \phi) = \frac{\left(\frac{\pi}{2} - g\right) \cos g + \sin g}{\cos \theta_i + \cos \theta_v} - \frac{\pi}{4}, \quad (4.9)$$

kde g je definováno vztahem 4.6. Geometrické jádro je pak definováno jako

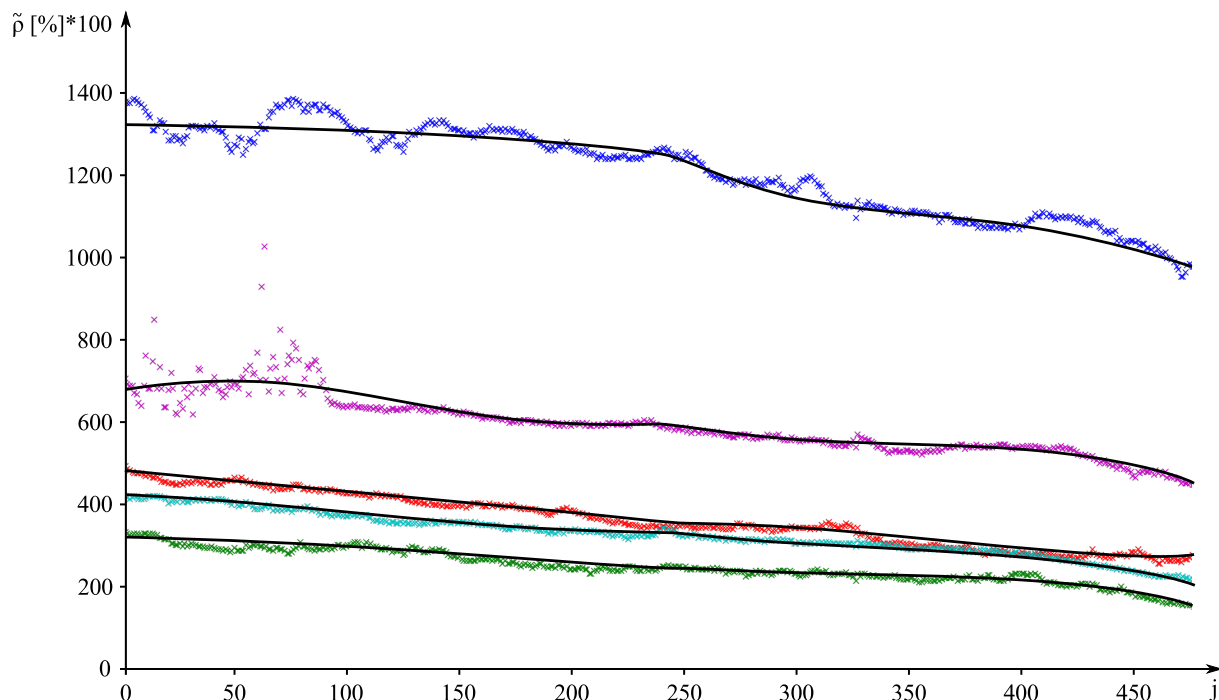
$$K_{geo}(\theta_i, \theta_v, \phi) = \frac{(\pi - \phi) \cos \phi + \sin \phi}{2\pi} \operatorname{tg} \theta_i \operatorname{tg} \theta_v - \frac{1}{2} \left[\operatorname{tg} \theta_i + \operatorname{tg} \theta_v + \sqrt{\operatorname{tg}^2 \theta_i + \operatorname{tg}^2 \theta_v - 2 \operatorname{tg} \theta_i \operatorname{tg} \theta_v \cos \phi} \right]. \quad (4.10)$$

Tento model je velmi obecný a proto jej autoři v [12] používají pro různé typy pokryvů.

4.3 Výsledná normalizace

Dalším krokem je proložení vypočítaných charakteristik vhodným modelem. Výběr modelu je zde opravdu důležitý, neboť je třeba zvolit takový, který vhodně popisuje odrazivé chování daného pokryvu. Avšak neexistuje pravidlo, které by určilo, jaký model použít.

Je zřejmé, že BRDF modely jsou převážně nelineární vzhledem k úhlovým proměnným, a proto se pro prokládání hodí právě nelineární metody nejmenších čtverců popsané v kapitole 1.2.2. Z důvodů přesnější fyzikální interpretace je vhodné vypočítané charakteristiky rozdělit na dvě části (podél středu letové linie na „levou“ a „pravou“ část) a každou pak prokládat zvlášť, neboť tyto části se mohou chovat odlišně. Obrázek 4.8 znázorňuje takovéto proložení vypočítaných charakteristik (uvedených na obrázku 4.6) Roujeanovým modelem.



Obrázek 4.8: Vypočítané charakteristiky proložené BRDF modelem.

Výsledkem metody nejmenších čtverců jsou pak takové koeficienty, pro které použitý model co nejlépe aproximuje vypočítané charakteristiky. Cílem tedy bude z tohoto modelu odvodit normalizační funkci, aby se pomocí ní BRDF efekt minimalizoval co nejvíce.


Jak již bylo dříve uvedeno, cílem je normalizovat datový soubor napříč snímanou linií. Nechť R je tedy vhodný BRDF model, který se převede z úhlové závislosti $(\theta_i, \theta_v, \phi, \dots)$ na závislost na sloupcích j (toto je možné za předpokladu, že jsou známy vlastnosti snímacího zařízení a přesná poloha Slunce při snímání) a pomocí metod nejmenších čtverců se určí příslušné koeficienty. Pak lze odvodit normalizační funkci N z modelu R takto

$$N(j) = R(\bar{j}) / R(j), \quad (4.11)$$

kde j jsou sloupce a \bar{j} označuje prostřední sloupec reprezentující střed letové linie. Pomocí uvedeného postupu se vypočítají normalizační funkce $N_{k,l}$ pro všechny klasifikační třídy l a pro všechna spektrální pásma k . Výsledně se už jen hodnoty v datovém souboru vynásobí hodnotami z příslušných normalizačních funkcí. Toto se dá popsat následovně

$$a_{i,j,k}^* = \sum_{l=1}^n a_{i,j,k} \cdot N_{k,l}(j) \cdot \chi_l(a_{i,j,k}), \quad (4.12)$$

kde $a_{i,j,k}^*$ je výsledný normalizovaný datový soubor, n je počet klasifikačních tříd a χ_l je charakteristická funkce třídy l — tzn., že nabývá hodnoty 1 pokud pixel $a_{i,j,k}$ náleží do třídy l a hodnoty 0 pokud do této třídy nenáleží. Pokud se pro takto normalizovaná data opět vypočítají výše uvedené charakteristiky, měl by být již BRDF efekt minimalizován. Toto ukazuje obrázek 4.9.



Obrázek 4.9: Vypočítané charakteristiky (medián) pro normalizovaná data.

5 Softwarová implementace

Důležitou součástí této práce je balík skriptů pro programové prostředí MATLAB.⁵ Tento balík obsahuje jak samotné dílčí skripty pro základní kroky algoritmu, tak skripty využívající tyto základní kroky pro komplexnější výpočty. Uživatel tak může používat tyto jednotlivé dílčí skripty pro manipulaci a vizualizaci datového souboru. Výsledně pak může pomocí jediného skriptu provést na celém datovém souboru výslednou nadir normalizaci.

Pro skripty nebylo vytvořeno grafické rozhraní. Všechny skripty se tedy volají pomocí textových příkazů z příkazové řádky programového prostředí (každý skript obsahuje ukázkové volání). Toto umožňuje uživateli si vytvořit vlastní volání potřebných skriptů, a tak automatizovat jednotlivé kroky pro více datových souborů. Taktéž je velmi snadné upravovat jednotlivé vstupy (pomocí syntaxe programového prostředí MATLAB), či si přizpůsobit samotné části skriptů. Ve výsledku tak lze tyto skripty použít v komplexnějším programu, který využívá jednotlivé skripty (či jejich kombinaci).

Je třeba zdůraznit, že při samotné nadir normalizaci hraje důležitou roli volba vhodných modelů, jejich parametrů i nastavení algoritmů pro řešení problému nejmenších čtverců. Samotné skripty nejsou samy schopny navrhnout vhodný BRDF model, toto záleží pouze na uživateli. Některé skripty ale mohou pomoci uživateli určit, který z množiny různých modelů popisuje daný BRDF efekt nejlépe.

Cílem této kapitoly je přiblížit jednotlivé skripty (jejich vstupy, výstupy a způsoby výpočtů) a popis jejich použití pro výslednou nadir normalizaci.

5.1 Popis jednotlivých skriptů

Vypracované skripty dovolují pracovat s datovými soubory ve formátu **.bsq*. Z důvodu velké paměťové náročnosti těchto souborů jsou při výpočtech vždy načítány pouze hodnoty aktuálně používaného spektrálního pásma (toto dovoluje algoritmus nadir normalizace — každé spektrální pásmo se normalizuje samostatně). Dále umožňují otevřít soubor klasifikační masky (udává klasifikační třídu každého pixelu), který bývá taktéž uchovávan ve formátu **.bsq*.

Jak již bylo uvedeno, skripty se volají pomocí textových příkazů z příkazové řádky programového prostředí. V tomto případě je důležité dodržet strukturu a typ vstupních hodnot. Z tohoto důvodu budou dále popsány nejčastěji používané vstupní proměnné:

- *fname* — úplná (nebo relativní) cesta vstupního souboru — textový řetězec,
- *datatype* — číselná reprezentace použitého datového typu a způsobu uspořádání hodnot v datovém souboru (uvedeno v hlavičkovém souboru vstupního souboru),
- *r* — počet řádků vstupního datového souboru,
- *s* — počet sloupců vstupního datového souboru,
- *t* — počet spektrálních pásem vstupního datového souboru,
- *maskfname* — úplná (nebo relativní) cesta souboru klasifikační masky — textový řetězec,

⁵Z důvodu kompatibility s licencovanou verzí na CVGZ byly skripty psány a testovány pro verzi MATLAB 2012a.

NORMALIZACE HYPERSPEKTRÁLNÍCH OBRAZOVÝCH DAT

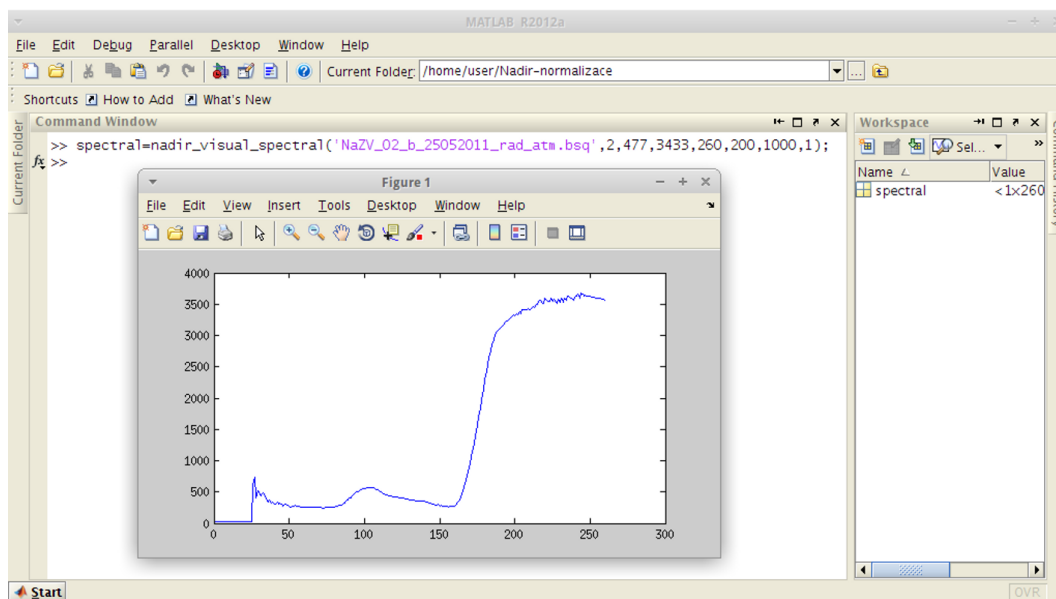
- *outputfname* — úplná (nebo relativní) cesta výstupního souboru — textový řetězec,
- *b* — pořadí spektrálního pásma (pro skripty pracující pouze s jedním spektrálním pásmem),
- *x* — vodorovná souřadnice obrazového bodu (pro skripty pracující pouze s jedním obrazovým bodem),
- *y* — svislá souřadnice obrazového bodu (pro skripty pracující pouze s jedním obrazovým bodem),
- *options* — nastavení algoritmu pro řešení problému nejmenších čtverců,
- *fce* — sloupcová matice obsahující BRDF modely pro každou klasifikační třídu,
- *fce_{x0}* — sloupcová matice obsahující startovací vektory pro každý BRDF model.

V dalších částech bude uveden základní popis a funkce jednotlivých skriptů.

5.1.1 Vizualizace datového souboru

Mnohdy se před samotnou normalizací vyplatí hodnoty v datovém souboru vhodně vizualizovat. Jednou z dříve popsanych metod je vykreslení spektrální křivky odrazivosti. K tomuto slouží skript `nadir_visual_spectral`. Jeho výstup je znázorněn na obrázku 5.1. Další možností je vykreslení histogramu pro zadané spektrální pásmo. Toto lze provést pomocí skriptu `nadir_visual_hist`.

Posledním způsobem je přímá vizualizace. Tuto generuje skript `nadir_visual_RGB`, kde vstupem jsou spektrální pásma, která budou použita pro jednotlivé barevné složky digitálního obrazu.



Obrázek 5.1: Programové prostředí MATLAB a výstup skriptu `nadir_visual_spectral`.

5.1.2 Nadir normalizace

Pro přípravu vhodného BRDF modelu slouží skript `nadir_tool_fit`. Zde si může uživatel vizualizovat (pro dané spektrální pásmo) proložení vypočítaných charakteristik sloupců zadaným BRDF modelem. Výstupem jsou navíc různé číselné charakteristiky (součet čtverců reziduí, použité stop kritérium algoritmu, atd.). Jak by pro dané spektrální pásmo dopadla výsledná nadir normalizace (pro zvolený BRDF model) pak zobrazuje skript `nadir_tool_fit_normalization`.

K samotné výsledné nadir normalizaci slouží skript `nadir_normalization`. Vstupem jsou kromě parametrů vstupního souboru také klasifikační maska a BRDF modely pro každou klasifikační třídu. Výstupem je pak datový soubor (datatype 2 — tzn. datový typ `uint16` a uspořádání `BSQ`).

Algoritmus nadir normalizace je ve skriptu implementován tak, aby jej bylo případně možno optimálně počítat na vícejádrových procesorech. Pokud tedy uživatel spustí tento skript v rozhraní `matlabpool`⁶, bude výpočet probíhat paralelně pro několik spektrálních pásem najednou (záleží na typu procesoru).

Skript `nadir_tool_normalization_compare` slouží pro srovnání výsledků nadir normalizace. Vstupem jsou dva datové soubory, které mají na krajích překrývající se části. Dále musí uživatel vložit souřadnice shodných bodů v obou souborech. Skript vypočítá odchylky v těchto souřadnicích. Takto se dají určit odchylky před a po nadir normalizaci. Neboť není možné vybrat vždy naprosto shodné body v obou souborech, pro výpočet odchylek se průměruje okolí vybraných dvojic bodů.

5.2 Shrnutí

Samotné skripty jsou umístěny na DVD, které je přiloženo k této práci. Zde se také nachází malé výřezy z poskytnutých letových linií, které slouží pouze pro názornou demonstraci funkčnosti přiložených skriptů.

Práce s těmito skripty probíhá podle klasických pravidel pro práci s textovými příkazy. Uživatel musí mít pouze tyto skripty nakopírovány v aktivním adresáři programového prostředí MATLAB. Z tohoto důvodu je nutné mít uloženy všechny skripty v jednom společném adresáři — skripty jsou na sebe mnohdy navázány.

Výhodou použitého programového prostředí MATLAB je kvalitní implementace základních rutinních matematických operací a různých algoritmů (pro potřeby této práce především implementace algoritmů pro řešení problému nejmenších čtverců, které byly popsány v první kapitole). Dále zde lze jednoduše naprogramovat algoritmy pro vícejádrové procesory — nadir normalizaci tak lze počítat pro více spektrálních pásem najednou. Obě tyto výhody umožňují relativně rychlý výpočet vstupního souboru (vše ovšem závisí na hardwarových specifikacích výpočetního stroje, rozsáhlosti datového souboru, množství klasifikačních tříd a složitosti jednotlivých BRDF modelů). Snahou také bylo napsat uvedené skripty s důrazem na vhodnou syntaxi tak, aby probíhal výpočet co nejoptimálněji. I přesto se ale nejedná o profesionální a nejefektivnější implementaci popsánoho způsobu řešení problému nadir normalizace.

⁶Tento příkaz vyžaduje Parallel Computing Toolbox. Více ohledně paralelních výpočtů v programovém prostředí MATLAB lze nalézt na: <http://www.mathworks.com/help/distcomp/index.html>.

6 Zhodnocení funkčnosti implementovaného algoritmu

Jak již bylo uvedeno v třetí kapitole, hlavním objektem této práce jsou reálné letové linie hyperspektrálních obrazových dat, které pro účely této práce poskytlo CVGZ. Tato kapitola se bude zabývat zhodnocením výsledků nadir normalizace provedené u těchto letových linií⁷ s využitím softwarové implementace, která byla popsána v předešlé kapitole a je důležitou součástí této práce.

6.1 Porovnání jednotlivých BRDF modelů

Pro porovnání výsledků byly vybrány dvě letové linie (*NaZV_03_25052011_rad_atm.bsq* a *NaZV_04_25052011_rad_atm.R.bsq*), které se na krajích překrývají. Pro obě letové linie byly vypočítány klasifikační masky metodou neuronových sítí (pomocí ENVI Software-Image Analysis Software). Každý z pixelů se tedy klasifikoval do jedné z pěti klasifikačních tříd: *holá_půda*, *les*, *vegetace_1*, *vegetace_2*⁸ a *řepka*. Závěrem byly pomocí postklasifikačního filtru obě masky vyhlazeny.

Následně se pro obě letové linie vypočítaly nadir normalizace. Jednou se pro všechny třídy pokryvu použil *Rahmanův* a podruhé *Roujeanův* model. Navíc se pro srovnání vypočítaly v programu ENVI pro obě letové linie tzv. *Cross-Track Illumination Correction*⁹ (korekce osvětlení napříč linií, dále jen *CTIC*). Tato korekce prokládá jednotlivé řádky datového souboru polynomem zvoleného stupně a následně vypočítá výslednou korekci. Avšak nebere v úvahu jednotlivé třídy pokryvu. Pro konkrétní výpočet *CTIC* pro obě letové linie byl zvolen polynom třetího stupně.

Dále bylo na překryvu obou linií vybráno 40 dvojic odpovídajících si pixelů. Tyto posloužily pro výpočet součtů kvadrátů odchylek jednotlivých hodnot spektrální odrazivosti daných dvojic pixelů. Pro výpočet se u každého pixelu průměrovalo okolí 3×3 pixelů a navíc se braly spektrální pásma v rozmezí 500 – 800 nm, neboť naměřená data netrpí v tomto rozmezí tak velkým šumem, který se vyskytuje např. nad 800 nm.

Tyto součty kvadrátů odchylek se určily jak pro původní letové linie, tak pro letové linie normalizované pomocí *Rahmanova modelu*, *Roujeanova modelu* a *CTIC*. Konkrétní hodnoty pro daný způsob normalizace a danou třídu pokryvu jsou uvedeny v tabulce 6.1. Pro lepší názornost jsou v tabulce 6.2 hodnoty pro danou klasifikační třídu vyděleny hodnotou celkového součtu kvadrátů odchylek spektrální odrazivosti bez nadir normalizace.

Z uvedených tabulek vyplývá, že pro klasifikační třídy *holá_půda*, *les* a *řepka* dosáhl *Roujeanův model* nejlepších výsledků. Konkrétně u tříd *holá_půda* a *řepka* došlo k výraznému snížení BRDF efektu. Pro třídu *les* už výsledek není tak markantní. Avšak pro tuto klasifikační třídu je nadir normalizace z podstaty náročná - vysoká členitost a rozmanitost třídy. Z tohoto důvodu je také obtížné vybrat vhodné dvojice odpovídajících si bodů pro porovnávání.

⁷Nadir normalizace a následné zhodnocení bylo provedeno na kompletních letových liniích. Na příloženém DVD lze nalézt pouze malé výřezy těchto letových linií, které slouží jen pro praktickou demonstraci funkčnosti příložených skriptů.

⁸Klasifikační třídy *vegetace_1* a *vegetace_2* nebyly určeny apriori podle určitého typu vegetace, nýbrž na základě pixelů s obdobným spektrálním chováním. Mohou tedy reprezentovat více druhů vegetace.

⁹Více informací viz. URL: <http://geol.hu/data/online_help/Preprocessing-Utilities.html>.

	bez normalizace	Rahmanův model	Roujeanův model	CTIC
Holá_půda	$2,71 \cdot 10^8$	$2,45 \cdot 10^8$	$4,07 \cdot 10^7$	$4,68 \cdot 10^7$
Les	$4,11 \cdot 10^7$	$3,55 \cdot 10^7$	$2,93 \cdot 10^7$	$3,97 \cdot 10^7$
Vegetace_1	$9,51 \cdot 10^7$	$8,24 \cdot 10^7$	$8,93 \cdot 10^7$	$1,25 \cdot 10^8$
Vegetace_2	$1,09 \cdot 10^7$	$1,15 \cdot 10^7$	$4,98 \cdot 10^7$	$2,73 \cdot 10^7$
Řepka	$5,18 \cdot 10^7$	$5,35 \cdot 10^7$	$1,55 \cdot 10^7$	$6,65 \cdot 10^7$

Tabulka 6.1: Celkový součet kvadrátů odchylek spektrálních odrazivostí vybraných dvojic odpovídajících si pixelů letových linií pro jednotlivé BRDF modely a klasifikační třídy.

	bez normalizace	Rahmanův model	Roujeanův model	CTIC
Holá_půda	1	0,90	0,15	0,17
Les	1	0,86	0,71	0,96
Vegetace_1	1	0,87	0,94	1,31
Vegetace_2	1	1,05	4,55	2,50
Řepka	1	1,03	0,30	1,28

Tabulka 6.2: Hodnoty celkových součtů kvadrátů odchylek spektrálních odrazivostí vybraných dvojic odpovídajících si pixelů jednotlivých klasifikačních tříd a BRDF modelů přepočítaných na poměr k hodnotám bez nadir normalizace.

Problémem jak pro oba BRDF modely, tak i pro CTIC byly klasifikační třídy *vegetace_1* a *vegetace_2*. Ani jeden z modelů nedokázal dostatečně zachytit chování těchto klasifikačních tříd. U *vegetace_2* navíc došlo ke zhoršení samotného BRDF efektu. Toto může být způsobeno tím, že dané třídy kombinují více druhů vegetace. Algoritmus pak nemůže vypočítat nejvhodnější normalizační funkci, která by zachytila chování všech druhů vegetace v dané třídě. S tímto také souvisí následný výběr dvojic odpovídajících si bodů z obou letových linií pro porovnávání. V těchto bodech totiž může být vegetace, kterou v dané klasifikační třídě nebyl model schopen zachytit.


Z výsledků CTIC je patrné, že tato korekce byla velmi ovlivněna pixely klasifikační třídy *holá_půda* (pro kterou dosáhla obdobného výsledku jak normalizace *Roujeanovým modelem*). Zde je totiž BRDF efekt nejmarkantnější a tato klasifikační třída zabírá v některých částech letové linie velkou plochu. Tím, že CTIC nebere v úvahu jednotlivé třídy pokryvu a byla ovlivněna BRDF efektem klasifikační třídy *holá_půda*, nedosáhla tato korekce pro ostatní třídy pokryvu tak kvalitních výsledků.

6.2 Zhodnocení

Z výše uvedených poznatků plyne, že navržený a implementovaný algoritmus je funkční. Avšak je nutné si uvědomit, že je důležité zvolit vhodný počet klasifikačních tříd. Pokud by jich bylo mnoho, samotná klasifikace by byla časově náročná, nemusela by být tak kvalitní a modely pak nemusí zachytit příslušný BRDF efekt v obecném měřítku. Naopak při malém počtu tříd se zde kombinuje několik druhů vegetace do jedné klasifikační třídy. Algoritmus pak není schopen dostatečně vhodně zachytit BRDF efekty všech druhů vegetace. S tímto také souvisí volba vhodného BRDF modelu pro konkrétní třídu pokryvu. Samotný algoritmus nedokáže vybrat konkrétní model - toto už záleží pouze na uživateli.

6. ZHODNOCENÍ FUNKČNOSTI IMPLEMENTOVANÉHO ALGORITMU

Samotný konečný výsledek nadir normalizace by se dal reprezentovat porovnáním přímého grafického výstupu původní a normalizované linie. Avšak rozdíly mezi těmito liniemi by nebyly pro lidské oko příliš patrné. Proto je pro grafické porovnání výhodnější grafická reprezentace rozdílu těchto dvou linií. Obrázek 6.1 znázorňuje takovýto rozdíl pro letovou linii NaZV_04_25052011_rad_atm_R.bsq, normalizaci *Roujeanovým modelem* a spektrální pásmo o vlnové délce 550 nm. Uvedený obrázek byl vytvořen tak, že se od hodnot normalizované letové linie odečetly hodnoty linie původní. Avšak digitální obraz nemůže obsahovat záporné hodnoty. Proto jsou kladné hodnoty reprezentovány modře a záporné hodnoty červeně. Čím je absolutní hodnota rozdílu pro daný pixel větší, tím větší je i hodnota dané barevné složky. Pro větší názornost byly všechny hodnoty vynásobeny vhodnou konstantou — pro plné využití použitého datového rozsahu digitálního obrazu.



Obrázek 6.1: Grafické znázornění rozdílu původní a normalizované letové linie.

Závěr

Letecký hyperspektrální dálkový průzkum Země slouží pro monitorování a analýzu různých složek životního prostředí. Jedná se o metody distančního zkoumání a měření zemského povrchu. V Centru výzkumu globální změny AV ČR pak takto naměřená data využívají pro fyzikálně založené odhady biofyzikálních a biochemických parametrů vegetace. Před provedením samotných odhadů je ovšem důležité naměřená data tzv. *předzpracovat*. Toto zahrnuje různé metody pro odstranění nepřesností měření, které mohou být způsobeny různými vlivy.

Cílem práce bylo navržení postupu pro vyrovnaní spekter odrazivosti (tzv. nadir normalizaci) napříč šířkou letové linie, přičemž východiskem byla statistická analýza spekter napříč linií. Důležitým požadavkem bylo provádět požadovanou normalizaci pro různé druhy povrchů zvlášť.

Požadovaný postup pro výpočet nadir normalizace byl úspěšně vypracován. Jeho jednotlivé kroky jsou popsány v kapitole 4.2. Byl navržen tak, aby jej bylo možné implementovat pro praktické výpočty na reálných datech. Samotná programová implementace je právě důležitou součástí této práce a byla blíže popsána v kapitole 5.1. Autorem naprogramovaný balík skriptů pro programové prostředí MATLAB je tedy plně funkční a může kromě samotné nadir normalizace sloužit také pro manipulaci a vizualizaci naměřených datových souborů. Funkčnost softwarové implementace dokazují výsledky, které byly v závěru práce prezentovány pro dvě reálné letové linie hyperspektrálních obrazových dat.

Programová implementace nabízí řadu možností pro další rozvedení a vylepšení jednotlivých vlastností. Jednou z možností by bylo upravení algoritmu tak, aby při normalizaci zohledňoval i vliv reliéfu (tato problematika ale přesahuje rozsah této práce). Dále by bylo možné vytvořit grafického rozhraní či zabudovat skripty do komplexnějšího programu.

Literatura

- [1] BARNESLEY, M.J. *Canopy Reflectance Model Inversion and the BRDF* [online]. Remote Sensing of the Land Surface, 2007 [cit. 2013-05-04]. URL: <http://www.peer.eu/fileadmin/user_upload/opportunities/metier/course3/c3.biophysical_vegetation_property_canopy.pdf>.
- [2] BJÖRCK, Å. *Numerical Methods for Least Squares Problems*. Philadelphia: SIAM Publications, 1996. 408 s. ISBN 0898713609.
- [3] ČERMÁK, L., HLAVIČKA, R. *Numerické metody*. Brno: CERM, 2005. 110 s. ISBN 80-214-3071-0.
- [4] DOBROVOLNÝ, P. *Dálkový průzkum Země. Digitální zpracování obrazu*. Brno: Masarykova univerzita, 1998. 208 s. ISBN 80-210-1812-7.
- [5] HLAVÁČ, V., ŠONKA, M. *Počítačové vidění*. Praha: Grada, 1992. 272 s. ISBN 80-85424-67-3.
- [6] KARPÍŠEK, Z. *Matematika IV - statistika a pravděpodobnost*. 3. dopl. vyd. Brno: CERM, 2007. 170 s. ISBN 978-80-214-3380-9.
- [7] KOLÁŘ, J., HALOUNOVÁ, L., PAVELKA, L. *Dálkový průzkum Země 10*. Praha: České vysoké učení technické, 1997, 164 s. ISBN 80-01-01567-X.
- [8] LILLESAND, T.M., KIEFER, R.W., CHIPMAN, J.W. *Remote sensing and image interpretation*. 5th ed. New York: John Wiley & Sons, 2008, 756 s. ISBN 0-470-05245-7.
- [9] MADSEN, K., NIELSEN, H.B., TINGLEFF, O. *Methods for non-linear least squares problems* [online]. 2nd ed. 2004, [cit. 2013-04-22]. URL: <http://www2.imm.dtu.dk/pubdb/views/edoc_download.php/3215/pdf/imm3215.pdf>.
- [10] RAHMAN, H., PINTY, B., VERSTRAETE, M.M. *Coupled surface-atmosphere reflectance (CSAR) model: 2. Semiempirical surface model usable with NOAA advanced very high resolution radiometer data*. Journal of Geophysical Research, 1993, vol. 98, no. D11, s. 20791–20801.
- [11] RICHTER, R., SCHLÄPFER, D. *Atmospheric / Topographic Correction for Airborne Imagery* [online]. ATCOR-4 User Guide, Version 6.2.1, Feb. 2013 [cit. 2013-05-04]. URL: <http://www.rese.ch/pdf/atcor4_manual.pdf>.
- [12] ROUJEAN, J.L., LEROY, M., DESCHAMPS, P.Y. *A Bidirectional Reflectance Model of the Earth's Surface for the Correction of Remote Sensing Data*. Journal of Geophysical Research, 1992, vol. 97, no. D18, s. 20455–20468.
- [13] SHUNLIN, L. *Quantitative remote sensing of land surfaces*. Hoboken, New Jersey: John Wiley & Sons, 2003. 534 s. ISBN 0-471-28166-2.
- [14] VOLNÁ, E. *Neuronové sítě a genetické algoritmy*. Vyd. 1. Ostrava: Ostravská univerzita, 1998, 141 s. ISBN 80-7042-762-0.

Seznam obrázků

1.1	<i>Naměřená data $\{(t_i, y_i)\}$ (ozn. +) proložená křivkou $M(\mathbf{x}^*, t)$.</i>	16
2.1	<i>Znázornění zenitního úhlu θ, azimutu φ a prostorového úhlu Ω.</i>	26
2.2	<i>Diagram odrazivosti pro čtyři hlavní typy povrchu: a) difuzní, b) zrcadlový, c) kombinovaný, d) rýhovaný.</i>	27
2.3	<i>Obecný průběh spektrální odrazivosti a) vody, b) vegetace, c) suché půdy a d) vlhké půdy.</i>	29
2.4	<i>Spektrální odrazivost: a) zdravé vegetace, b) vegetace brzy po stresu, c) vegetace po jisté době od stresu.</i>	29
3.1	<i>Způsob získávání dat pomocí pushbroom systému.</i>	32
3.2	<i>Naměřené spektrální odrazivosti pro vybraný pixel z datového souboru.</i>	33
3.3	<i>Přímá vizualizace výřezu dat.</i>	34
4.1	<i>Znázornění rozdílu úhlu snímání napříč snímanou linií.</i>	37
4.2	<i>Schéma formálního neuronu.</i>	40
4.3	<i>Struktura neuronové sítě.</i>	41
4.4	<i>Přímá vizualizace výstupu klasifikace — každá barva odpovídá určité třídě.</i>	42
4.5	<i>Přímá vizualizace výstupu postklasifikačního filtru aplikovaného na klasifikovaná data.</i>	43
4.6	<i>Vypočítané charakteristiky (v tomto případě medián) všech sloupců pro jednotlivé třídy pokryvu — jednotlivé třídy barevně rozlišeny.</i>	44
4.7	<i>Znázornění zenitního úhlu Slunce θ_i a zenitního pozorovacího úhlu θ_v.</i>	44
4.8	<i>Vypočítané charakteristiky proložené BRDF modelem.</i>	46
4.9	<i>Vypočítané charakteristiky (medián) pro normalizovaná data.</i>	47
5.1	<i>Programové prostředí MATLAB a výstup skriptu <code>nadir_visual_spectral</code>.</i>	50
6.1	<i>Grafické znázornění rozdílu původní a normalizované letové linie.</i>	55

Seznam tabulek

2.1	<i>Základní radiometrické veličiny s jejich fyzikálními rozměry a používanými symboly.</i>	24
3.1	<i>Technické informace o snímači.</i>	31
3.2	<i>Technické informace k nasnímaným datům.</i>	31
6.1	<i>Celkový součet kvadrátů odchylek spektrálních odrazivostí vybraných dvojic odpovídajících si pixelů letových linií pro jednotlivé BRDF modely a klasifikační třídy.</i>	54
6.2	<i>Hodnoty celkových součtů kvadrátů odchylek spektrálních odrazivostí vybraných dvojic odpovídajících si pixelů jednotlivých klasifikačních tříd a BRDF modelů přepočítaných na poměr k hodnotám bez nadir normalizace.</i>	54