

**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

**Fakulta elektrotechnická**

**Katedra teorie obvodů**

**Kompresní metody pro hyperspektrální zobrazování**  
**Compression Algorithms for Hyperspectral Imaging**

**leden 2019**

**Diplomant: Bc. Petr Hartmann**

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



## **Čestné prohlášení**

Prohlašuji, že jsem zadanou diplomovou práci zpracoval sám s přispěním vedoucího práce a používal jsem pouze literaturu v práci uvedenou. Dále prohlašuji, že nemám námitek proti půjčování nebo zveřejňování své diplomové práce nebo jejích částí se souhlasem katedry.

Datum: 8. 1. 2019

.....

podpis diplomanta



## I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Hartmann** Jméno: **Petr** Osobní číslo: **392779**  
Fakulta/ústav: **Fakulta elektrotechnická**  
Zadávající katedra/ústav: **Katedra teorie obvodů**  
Studijní program: **Komunikace, multimédia a elektronika**  
Studijní obor: **Komunikační systémy**

## II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

**Kompresní metody pro hyperspektrální zobrazování**

Název diplomové práce anglicky:

**Compression Algorithms for Hyperspectral Imaging**

Pokyny pro vypracování:

Seznamte se s principem hyperspektrálního zobrazování. Popište jeho princip, parametry a formáty dat, které se používají. Dále se zaměřte na kompresní metody a jejich principy, které se v hyperspektrálním zobrazování používají. Podejte jejich přehled. Vybrané metody po dohodě s vedoucím ověřte na sestavené testovací množině obrazových dat a výsledky porovnejte.

Seznam doporučené literatury:

- [1] G. Motta, F. Rizzo, a J. A. Storer, *Hyperspectral Data Compression*. Springer Science & Business Media, 2006.
- [2] S. Wright, A. Miguel, Dr., a J. Ashbach, 'Hyperspectral Image Compression', prezentováno v APS Northwest Section Meeting Abstracts, 2008.
- [3] Q. Du a J. E. Fowler, 'Hyperspectral Image Compression Using JPEG2000 and Principal Component Analysis', *IEEE Geosci. Remote Sens. Lett.*, roč. 4, č. 2, s. 201-205, dub. 2007.
- [4] S. Qian, *Optical Satellite Data Compression and Implementation*, SPIE PRESS BOOK, 2013.

Jméno a pracoviště vedoucí(ho) diplomové práce:

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

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

Datum zadání diplomové práce: **13.02.2018**

Termín odevzdání diplomové práce: **08.01.2019**

Platnost zadání diplomové práce: **30.09.2019**

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

doc. Ing. Radoslav Bortel, Ph.D.  
podpis vedoucí(ho) ústavu/katedry

prof. Ing. Pavel Ripka, CSc.  
podpis děkana(ky)

## III. PŘEVZETÍ ZADÁNÍ

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

\_\_\_\_\_ Datum převzetí zadání

\_\_\_\_\_ Podpis studenta



## **Anotace**

Práce zkoumá problematiku hyperspektrálních obrazových dat a jejich zpracování, zejména kompresi. Teoretický úvod je zaměřen na principy obrazového snímání a způsoby uložení digitální obrazové informace, zmiňuje rozdíly mezi snímky ve stupních šedé, barevnými, multispektrálními a hyperspektrálními obrazovými daty. Následně jsou definovány základní parametry a fyzikální principy akvizice těchto dat. Druhá polovina teoretické části je věnována nejčastěji používaným kompresním algoritmům. Praktická část začíná shrnutím veřejně dostupných multispektrálních a hyperspektrálních dat a podává srovnání jejich vlastností. Následně dochází k analýze dat Aviris, testování navržených kompresních metod na shodné množině dat a prezentování naměřených parametrů.

## **Klíčová slova**

Hyperspektrální zobrazování a komprese, diskrétní vlnková transformace, analýza hlavních komponent, transformace Karhunen-Loève, SPIHT, EZW, STW, MATLAB

## **Summary**

This thesis researches the subject of hyperspectral imaging and analysis, image compression in particular. The theoretical introduction is focused on imaging and ways in which digital image data are stored. A comparison between grayscale, color, multivariate and hyperspectral image data is presented. Subsequently main parameters and physical principles of image data acquisition are explained. The second half of the theoretical introduction is dedicated to the most commonly used compression algorithms. Experimental section begins with a summary of hyperspectral data sources that are available for public. Then the testing of Aviris data and designed algorithms takes place and the results are presented.

## **Index terms**

Hyperspectral imaging and compression, discrete wavelet transform, principal component analysis, Karhunen-Loève transform, SPIHT, EZW, STW, MATLAB





Tímto bych rád poděkoval panu prof. Mgr. Petr Pátovi Ph.D za vstřícný přístup, cenné rady a motivování k dokončení této práce. Dále bych rád poděkoval své rodině a přítelkyni za neutuchající podporu v průběhu celé doby mého studia.

# Obsah

1.	Úvod.....	1
2.	Obrazová informace a principy zobrazování.....	2
2.1	Elektromagnetické vlnění a spektrum.....	2
2.2	Human Visual System.....	3
2.3	Obrazová informace.....	7
2.4	Digitální obraz.....	8
2.4.1	2D obrazová data – hodnoty intenzity.....	8
2.4.2	2D obrazová data – RGB.....	9
2.4.3	3D obrazová data.....	9
2.4.4	4D a vícerozměrná obrazová data.....	11
2.5	Parametry digitálních obrazových dat.....	12
2.5.1	Rozlišení prostorové dimenze.....	12
2.5.2	Rozlišení intenzity.....	12
2.5.3	Rozlišení spektrální dimenze.....	13
2.5.4	Matematické operace – předzpracování.....	14
3.	Hyperspektrální a multispektrální obrazová data.....	16
3.1	Využití hyperspektrálního zobrazování.....	16
3.2	Spektrometrie a spektroskopie.....	17
3.3	Akvizice hyperspektrálních dat.....	20
3.3.1	Bodová akvizice.....	21
3.3.2	Liniová akvizice.....	22
3.3.3	Plošná akvizice hyperspektrálních dat.....	23
3.4	Distribuce Hyperspektrálních dat.....	24
3.5	Hyperspektrální zobrazovací systémy.....	24
3.6	Předzpracování hyperspektrálních dat.....	26
3.6.1	Body zájmu.....	26
4.	Kompresní metody.....	28
4.1	Základní rozdělení kompresních metod.....	28
4.2	Architektura kompresních metod pro hypersp. data.....	29
4.3	Trendy a směr vývoje hyperspektrální komprese.....	31
4.4	Metody transformace.....	32
4.4.1	PCA.....	33
4.4.2	Wavelet.....	35
4.4.3	KLT.....	39
4.4.1	DCT.....	40
4.5	Metody kvantizace.....	41
4.5.1	Vektorová kvantizace.....	41
4.6	Metody predikce.....	42
4.6.1	DPCM.....	43
4.7	Metody kódování.....	44
4.7.1	Huffmanovo kódování.....	44
4.7.2	RLC kódování.....	44
4.7.3	Aritmetické kódování.....	45
4.7.4	LZV kódování.....	45
4.7.5	EZW.....	45
4.7.6	SPIHT.....	45
5.	Hodnocení kompresních metod.....	46
5.1	Používané parametry.....	46
5.1.1	Míra zkreslení.....	46
5.1.2	SNR.....	47
5.1.3	MSE.....	47
5.1.4	PSNR.....	48
5.1.5	Entropie.....	49
5.1.6	Křížová spektrální korelace.....	49

## Obsah

6.	Veřejně dostupná hyperspektrální data .....	51
6.1	NASA .....	51
6.1.1	Aviris .....	51
6.2	USGS .....	53
6.2.1	Landsat8 .....	53
6.2.2	Hyperion .....	54
6.2.3	Sentinel .....	54
7.	Testovaná data .....	55
7.1	Příprava dat .....	55
7.2	Aviris .....	55
7.3	Analýza .....	57
7.3.1	Postup analýzy .....	57
7.3.2	TNTmips .....	59
7.3.3	Hyperkrychle .....	59
7.3.4	Redukce dat .....	61
7.4	Testování .....	62
7.4.1	Příprava testovaných algoritmů .....	62
7.4.2	DWT .....	62
7.4.3	PCA .....	65
7.4.4	DCT .....	66
7.4.5	KLT .....	67
7.4.6	Křížová korelace testovaných metod .....	68
8.	Navržené kompresní systémy .....	69
8.1	Příprava měření parametrů komprese .....	69
8.2	Naměřené parametry .....	70
8.3	Shrnutí výsledků .....	72
9.	Závěr .....	73

## Seznam použitých zkratek

Zkratka	Význam	Použito na straně (stranách)
HVS	Human Visual System	3, 4, 5, 46
MSE	Mean Squared Error	4, 46, 47, 48, 49, 68, 69, 72
PSNR	Peak Signal-to-Noise Ratio	4, 46, 47, 48, 49, 61, 69, 72, 73
RGB	Red, Green and Blue	6, 9, 10, 17, 51, 52, 53, 56, 58, 69
CIE	International Commission on Illumination	6
ROI	Region Of Interest	7, 26, 27
LUT	Lookup Table	9, 42
VNIR	Visible and Near-infrared	10, 16, 24
SWIR	Short-wavelength Infrared	10, 24, 25
NMR	Nuclear Magnetic Resonance	11
pH	Potential of Hydrogen	11
bpp	Bits Per Pixel	12, 70, 71
uint 8/16	Unsigned Integer (8/16 bit)	12
int 8/16	Signed Integer (8/16 bit)	12
px, Mpx, Gpx	Pixel, Megapixel, Gigapixel	15, 51, 52, 57, 62, 63, 64, 69
LCTFs	Liquid Crystal Tunable Filters	20, 23, 24
NIR	Near-infrared	14, 20, 23, 25
AOTFs	Acousto-optic Tunable Filters	20, 23
PGP	Prism-grating-prism	20
HEA	Hyperion Electronics Assembly	24
CEA	Cryocooler Electronics Assembly	24
NASA	National Aeronautics and Space Administration	25, 51, 54, 56
RLC	Run-length Coding	29, 33, 44, 45, 69
SPIHT	Set Partitioning In Hierarchical Trees	31, 42, 44, 45, 69, 72, 73
ORASIS	Optical Real-Time Adaptive Spectral Identification System	31
JPEG	Joint Photographic Experts Group	31, 33, 43, 51, 53
DPCM	Differential Pulse-code Modulation	32, 42, 43
FPGA	Field-programmable Gate Array	31
KLT	Karhunen–Loève Theorem / Transform	32, 33, 38, 39, 40, 67, 68, 69, 72, 73
SPECK	Set Partitioned Embedded block Coder Algorithm	33
EZW	Embedded Zerotrees of Wavelet Transforms	44, 45, 69, 70, 71, 73
PCA	Principal Component Analysis	31, 33, 34, 35, 39, 59, 65, 67, 68, 69, 72, 73

## Seznam použitých zkratek

Zkratka	Význam	Použito na straně (stranách)
DWT	Discrete Wavelet Transform	36, 37, 38, 62, 63, 64, 68, 69, 72, 73
CTW	Continuous Wavelet Transform	36
M-NVQ	Mean-normalised Vector Quantization	40
GLA	Generalized Lloyd Algorithmus	41
VQ	Vector Quantization	41
CALIC	Context-based, Adaptive, Lossless Image Codec	42, 43
BIL	Band Interleaved by Line	43
BSQ	Band Sequential	43
BIP	Band Interleaved by Pixel	43, 52
LZW	Lempel–Ziv–Welch	33, 44
STW	Spatial-orientation Tree Wavelet	45, 69
SNR	Signal-to-noise Ratio	46, 47
PMAD	Percentage Maximum Absolute Distortion	47
PMAE	Percentage Maximum Absolute Error	47
RAID	Redundant Array of Independent Disks	52
SDS	Safety Data Sheets	52
PEP	Performance Evaluation and Planning	52
TIFF	Tagged Image File Format	53, 54
NDVI	Normalized Difference Vegetation Index	10, 19, 53
WTC	World Trade Center	54
KSC	Kennedy Space Center	55
UTC	Coordinated Universal Time	57
WDR	Wavelet Difference Reduction	69
ASWDR	Adaptively Scanned Wavelet Difference Reduction	69
OMS	Opto-mechanical Subsystem	24

## Seznam obrázků

Obrázek 2.1 Elektromagnetická vlna. ....	2
Obrázek 2.2 Elektromagnetické spektrum. ....	3
Obrázek 2.3 Pozorování objektu pozorovatelem dle HVS. ....	4
Obrázek 2.4 Závislost normalizované absorbance na vlnové délce pro různé typy čípků. ....	6
Obrázek 2.5 Grafické porovnání jednorozměrného, RGB a hypersp. snímku obrazových dat. ....	10
Obrázek 2.6 Trojrozměrná datová struktura, tzv. hyperkrychle hyperspektrálního obrazu. ....	11
Obrázek 2.7 Porovnání rozlišení spektrální a prostorové dimenze pro různé metody snímání. ....	13
Obrázek 3.1 Odraz záření na povrchu pevného prášku. ....	18
Obrázek 3.2 Normovaná spektrální reflektance zkoumaných dat Aviris. ....	19
Obrázek 3.3 NDVI dat zkoumaných v kapitole 7.4. ....	19
Obrázek 3.4 Bodová akvizice hyperspektrálních dat. ....	21
Obrázek 3.5 Liniová akvizice hyperspektrálních dat. ....	22
Obrázek 3.6 Plošná akvizice hyperspektrálních dat. ....	23
Obrázek 3.7 Náskres elektroniky satelitu Hyperion. ....	25
Obrázek 3.8 Schéma snímače Aviris. ....	25
Obrázek 3.9 Multispektrální fotografie, červený čtverec představuje ROI. ....	27
Obrázek 4.1 Kompletní blokové schéma kodéru hyperspektrálních dat. ....	30
Obrázek 4.2 Kompletní blokové schéma dekodéru hyperspektrálních dat. ....	30
Obrázek 4.3 4 Filtry použité pro DWT typu Biorthogonal 3.5 v programu MATLAB. ....	36
Obrázek 4.4 2D DWT – způsob transformace obrazu pro jednotlivé úrovně dekompozice. ....	37
Obrázek 4.5 Blokové schéma 1D DWT a IDWT 2. řádu. ....	38
Obrázek 4.6 Blokové schéma 2D DWT a IDWT 1. řádu. ....	38
Obrázek 4.7 Blokové schéma VQ pro účely komprese obrazových dat. ....	41
Obrázek 5.1 Křížová spektrální korelace před a po odstranění absorpčních pásem vody. ....	50
Obrázek 7.1 Vybraná data – oficiální RGB náhled NASA. ....	56
Obrázek 7.2 Mapa Maui s vyznačeným přeletem snímače Aviris. ....	56
Obrázek 7.3 RGB náhledy v nepravých barvách (false-color) testovaných dat. ....	58
Obrázek 7.4 Hyperkrychle dat Aviris. ....	60
Obrázek 7.5 Hyperkrychle dat Aviris – detailní náhled nespojitosti spektra. ....	61
Obrázek 7.6 Průběh 3D DWT, vlnka biortogonálního typu. ....	63
Obrázek 7.7 Závislost doby výpočtu na úrovni a dimenzi dekompozice. ....	64
Obrázek 7.8 Výpočetní náročnost 1D vs. 2D DWT. ....	64
Obrázek 7.9 PCA – porovnání vlivu počtu odstraněných vlastních vektorů na kvalitu. ....	65
Obrázek 7.10 DCT v závislosti na použité škálovací matici. ....	66
Obrázek 7.11 KLT 1D a 2D – testování ztrátovosti navrženého algoritmu. ....	67
Obrázek 7.12 Porovnání vlivu typu komprese na korelaci spektrálních kanálů. ....	68

## Seznam tabulek

Tabulka 3.1 Srovnání spektroskopie, klasického zobrazování a spektrálního zobrazování.....	18
Tabulka 6.1 Parametry zkoumaného hyperspektrálního snímku Aviris. ....	52
Tabulka 6.2 Parametry zkoumaného multispektrálního snímku Landsat8. ....	53
Tabulka 6.3 Parametry zkoumaného hyperspektrálního snímku Hyperion EO-1.....	54
Tabulka 6.4 Parametry zkoumaného multispektrálního snímku Sentinel.....	54
Tabulka 7.1 Detailnější parametry zkoumaných dat Aviris.....	57
Tabulka 8.1 Naměřené parametry pro metody 1D, 2D a 3D diskrétní vlnkové transformace. ....	70
Tabulka 8.2 Naměřené kompresní parametry pro metody 1D a 2D KLT, 2D PCA. ....	71
Tabulka 8.3 Naměřené parametry bez aplikace jakékoliv transformace nebo metody. ....	71
Tabulka 8.4 Souhrn navržených funkcí pro software MATLAB. ....	72

## Seznam rovnic

Rovnice 2.1 Vlnové rovnice šíření elektromagnetického vlnění. ....	2
Rovnice 2.2 Detekce objektu HVS. ....	4
Rovnice 2.3 Distribuce energie příchozí světelné energie. ....	5
Rovnice 2.4 Výpočet souřadnic RGB. ....	6
Rovnice 3.1 Vztah energie, frekvence a vlnové délky. ....	19
Rovnice 4.1 Vstupní data PCA. ....	34
Rovnice 4.2 Výpočet kovarianční matice. ....	34
Rovnice 4.3 Proces PCA. ....	35
Rovnice 4.4 Inverzní PCA. ....	35
Rovnice 4.5 Škálování vlnky. ....	36
Rovnice 4.6 Vztah šk. faktoru k časové a frekvenční oblasti. ....	36
Rovnice 4.7 Časový posuv vlnky. ....	37
Rovnice 4.8 Kovarianční matice $r_{i,j}$ .....	39
Rovnice 4.9 Vztak kovarianční matice a diagonální matice vlastních čísel. ....	39
Rovnice 4.10 Matematický popis získání báze vektorů DCT. ....	40
Rovnice 4.11 Délka jednoho kódového slova Huffmanova kódování. ....	44
Rovnice 5.1 Shannon-Hartleyho teorém.....	47
Rovnice 5.2 Obecná definice výpočtu MSE. ....	48
Rovnice 5.3 Výpočet MSE pro dva hyperspektrální diskrétní snímky X a Y. ....	48
Rovnice 5.4 Definice výpočtu PSNR. ....	49
Rovnice 5.5 Definice entropie trojrozměrných dat obrazových dat. ....	49
Rovnice 5.6 Výpočet normalizované křížové korelace trojrozměrné matice G. ....	50





# 1. Úvod

Práce se věnuje oblasti multispektrálních a hyperspektrálních obrazových dat, zejména pak jejich analýze a kompresi. Jde o vědní obor, jehož vývoj byl nastartován zejména potřebami satelitního snímání zemského povrchu. Na rozdíl od běžného snímání klasickými barevnými fotografiemi poskytuje hyperspektrální zobrazování detailní informaci o spektru vlnových délek, zaznamenaných na každém pixelu daného snímku. Tato spektra poskytují mj. informace o materiálu v daném místě a jeho vlastnostech. Satelitní snímání tyto informace využívá například pro detekci různých hornin v dané oblasti, zemědělství pro určení, je-li plodina dostatečně zralá, hydratovaná atd. Miniaturizace a snižování pořizovacích nákladů hyperspektrálních snímačů umožňují rozšíření této technologie do různých odvětví průmyslu i soukromého sektoru. Zůstává však přítomen problém, pramenící z podstaty hyperspektrálního zobrazování a tím je generování obrovského množství dat, jejichž komprese je náročná, protože většina aplikací vyžaduje co nejmenší zkreslení zdrojových dat, vysokou rychlost zpracování a nízkou výpočetní náročnost.

Cílem této práce bylo srovnat kompresní metody, které již byly navrženy a uvedeny v praxi. Bohužel, žádná kompletní metoda nebyla poskytnuta. Bylo tedy nutné na základě informací z dostupné literatury navrhnout vlastní kompresní řetězce. Ty byly realizovány v programu MATLAB, následně došlo k jejich testování, měření kompresních parametrů a vyhodnocení výsledků.

## 2. Obrazová informace a principy zobrazování


### 2.1 Elektromagnetické vlnění a spektrum

V klasické fyzice je elektromagnetické vlnění chápáno podle [1] jako tok energie, šířící se rychlostí světla volným prostorem nebo materiálem. Energie se šíří ve formě vln (viz Obrázek 2.1), skládajících se z navzájem ortogonálních elektrických a magnetických vektorových polí, u nichž dochází k příčnému vychylování amplitudy v čase, tedy k chování analogickému k vychylování částic napnuté struny, nebo ke změnám tlaku, vyvolaným šířící se zvukovou vlnou [2]. Mezi tato vlnění se řadí například rádiové vlny, viditelné světlo nebo gama paprsky. Mezi základní charakteristiky vlny patří její intenzita a frekvence, šíření je definováno dle Maxwellových rovnic (Rovnice 2.1). Spektrum frekvencí elektromagnetického vlnění obsahuje velký rozptyl hodnot od velmi malých (rádiové a televizní vlny), přes mikrovlny a viditelné světlo, až po výrazně vyšší hodnoty, mezi něž patří například ultrafialové světlo a gama paprsky (viz. Obrázek 2.2).

$$\begin{aligned}\nabla^2 \vec{B} &= \mu_0 \varepsilon_0 \frac{\partial^2 \vec{B}}{\partial t^2} \\ \nabla^2 \vec{E} &= \mu_0 \varepsilon_0 \frac{\partial^2 \vec{E}}{\partial t^2}\end{aligned}\tag{2.1}$$

**Rovnice 2.1** Vlnové rovnice šíření elektromagnetického vlnění.

$E$  je elektrické vektorové pole [ $\frac{V}{m}$ ],  $B$  je magnetické vektorové pole [ $\frac{N}{A \cdot m}$ ],  $\nabla$  označuje operaci divergence,  $\mu_0$  je permeabilita vakua  $4\pi \cdot 10^{-7}$  [ $\frac{H}{m}$ ] a  $\varepsilon_0$  je permitivita vakua  $8,85 \cdot 10^{-12}$  [ $\frac{F}{m}$ ]. Zdroj [3]




**Obrázek 2.1** Elektromagnetická vlna.

$E$  je elektrické vektorové pole,  $B$  magnetické vektorové pole,  $\lambda$  je vlnová délka a  $c$  rychlost šíření vlny. Zdroj [1].

## 2.2 Human Visual System

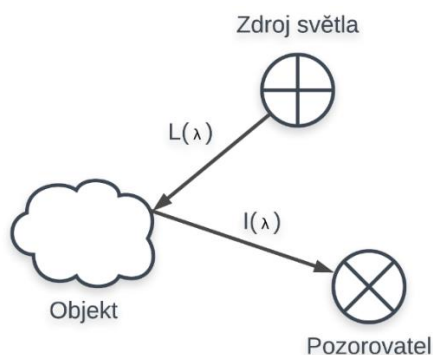
Human Visual System (zkráceně HVS) je termín, kterým se v multimediální technice označuje lineární model lidského vnímání obrazové informace, isotropický v prostorové doméně [3]. Model uvažuje fyziologii vidění za optický systém – zornice má účel clony (ovlivňuje množství světla, plní úlohu filtru dolní propusti [4]). Obraz je následně promítán na sítnici, která obsahuje dva typy fotoreceptorů – tyčinky a čípky. Velikost promítnutého objektu se odvíjí od úhlu dopadu paprsku světla [4]. Model slouží mj. pro pochopení redundance obrazových dat za účelem dosažení lepší efektivity kompresních algoritmů a současné minimalizace degradování kvality. Pro model HVS je důležitá jen relativně úzká část elektromagnetického spektra [5], odpovídající viditelnému světlu. Obecně se předpokládá [3], že evoluce lidského zraku byla silně ovlivněna naším sluncem, které produkuje nejvíce energie právě v této části elektromagnetického spektra. Podle [4] se odhaduje, že až polovina neuronů lidského mozku je asociovaná právě se zpracováním obrazové informace.



Obrázek 2.2 Elektromagnetické spektrum.

Převzato a upraveno z [1]

Mezi nejdůležitější parametry HVS patří percepce zkreslení komprimovaného obrazu a variace jasu. Nejvíce je HVS podle [5] citlivý na střední vlnové délky viditelného spektra a nejméně na ty nejvyšší vlnové délky. Dále je vizuální percepce zkreslení méně citlivá na velké změny jasu a relativní citlivost HVS má charakter pásmové propusti a ignoruje informaci, která je pro lidské oko nezpracovatelná z důvodu úspory výpočetní náročnosti navrhovaného systému a úspory přenášených dat. Obecný proces detekce objektu modelem HVS může být popsán rovnicí (Rovnice 2.1), popisovaná situace je znázorněna na obrázku (Obrázek 2.3). Pokud jsou pozorovaný objekt, zdroj světla i pozorovatel ve stacionární poloze, spektrum  $I(\lambda)$  bude mít stejný rozsah frekvencí jako  $L(\lambda)$ , spektrum jako takové se však bude lišit v závislosti na odrazivých vlastnostech  $\rho(\lambda)$  [4]. Po přijetí distribuce energie  $I(\lambda)$  je nastartován komplexní proces převodu světla do obrazové informace, tato energie bývá v literatuře ([6], [7], [8] aj.), zabývající se vzdáleně snímanými obrazovými daty, označována termínem radiance a konkrétně jde o hrubá naměřená data, nasnímaná senzorem. Společně s tímto termínem bývá spojován další termín reflektance, tedy poměr absorbovaného a odraženého záření.



**Obrázek 2.3** Pozorování objektu pozorovatelem dle HVS.

*$L(\lambda)$  je distribuce energie zdroje světla,  $I(\lambda)$  je světlo přijaté pozorovatelem.*

Navzdory dlouhému vývoji tohoto modelu si HVS stále zachovává určité nedokonalosti. Mezi ty hlavní patří podle [3] absence metriky měřící zkreslení a vlivu komprese na podobu dat – oba případy jsou dosud řešeny subjektivním hodnocením skupinou pozorovatelů. Další nevýhodou je fakt, že srovnávání probíhá až na finálním produktu, není možné takto srovnávat například jednotlivé segmenty, ačkoliv právě v těchto detailech může docházet k největším rozdílům. Pro tyto účely se využívá například MSE, nebo PSNR (Mean Squared Error, resp. Peak Signal-to-Noise Ratio, viz kapitola 5.1.).

$$I(\lambda) = \rho(\lambda)L(\lambda) \quad 2.2$$

**Rovnice 2.2** Detekce objektu HVS.

*$L(\lambda)$  je distribuce energie zdroje světla,  $I(\lambda)$  je světlo přijaté pozorovatelem a  $\rho(\lambda)$  je odrazivost pozorovaného objektu.*

Tyčinek má lidské oko zhruba 100 milionů, zajišťují skotopické vidění (černobílé při slabé intenzitě světla), čípků zhruba 7 milionů, ty slouží pro fotopické vidění (barevné vidění za dobrých světelných podmínek). Jako poslední termín zmiňuje [4] je mezopické vidění, tedy stav, během nějž jsou aktivovány oba typy fotoreceptorů (tedy barevné vidění za běžných světelných podmínek). Právě mezopické vidění uvažuje model HVS. Fotoreceptory nejsou na sítnici umístěny homogenně – čípky jsou nejhustší v oblasti středu žluté skvrny (*fovea centralis*) a dramaticky ubývají se zvyšujícím se úhlem. V těsné blízkosti optického nervu se pak nenachází vůbec žádné fotoreceptory, o jeho okolí tak mluvíme jako o slepém bodu.

Při kontaktu fotoreceptoru se světlem vzniká fotochemická reakce, produkující nervový impuls, který se přenáší nervovými vlákny, kterých oko obsahuje asi 0,8 milionu. Oblast žluté skvrny disponuje nejvyšší ostrostí obrazu, tyto vlastnosti jsou udrženy zhruba v rozptylu 1-2° stupňů od středu sítnice [3]. Ostrost vidění je tedy velmi závislá na úhlu pozorování. Informace o kontrastu a postranní inhibici poskytuje nelineární odezva čípků a tyčinek, a přenosová modulační funkce [4].

$$L = \int_0^{\infty} I(\lambda)V(\lambda)d\lambda \quad (2.3)$$

**Rovnice 2.3 Distribuce energie příchozí světelné energie.**

*Kde  $L(\lambda)$  je distribuce energie zdroje světla,  $I(\lambda)$  je světlo přijaté pozorovatelem a  $V(\lambda)$  je funkce relativní světelné účinnosti.*

Další důležitou oblastí HVS je reprezentace barvy. Ačkoliv je lidské oko schopné rozlišit pouze několik stovek stupňů šedé, je schopno rozlišit tisíce barev. Tři hlavní percepční atributy barvy jsou podle [4] – jas (vnímaná jasnost objektu), odstín (poměr barev) a saturace (míra, jak moc se vnímaná barva liší od achromatické). HVS reprezentuje barvy mixováním tří primárních barev, což reflektuje přítomnost třech různých typů čípků v lidské sítnici [3]. Závislost absorpčních spekter těchto tří typů čípků,  $S_R(\lambda)$ ,  $S_G(\lambda)$  a  $S_B(\lambda)$  na přijaté vlnové délce světla je zobrazena (Obrázek 2.4), na této závislosti je založena teorie tristimulu [3]. Pokud je spektrální distribuce barvy příchozího světla  $C(\lambda)$ , excitace třech zmíněných typů čípků může být vypočítána dle Rovnice 2.4 [3]. Za poznamenání stojí fakt, že pokud dvě rozdílné spektrální distribuce  $C_1(\lambda)$  a  $C_2(\lambda)$  produkují identické souřadnice  $\{\alpha_R, \alpha_G, \alpha_B\}$ , budou subjektivně barvy identické, ačkoliv mají rozdílné spektrální distribuce [3]. Mícháním barev z primárních barevných složek se dále zabývá kolorimetrie, ta mj. definuje, že použitím maximálního počtu tří různých světél lze namíchat jakoukoliv cílovou barvu, luminiscence barevné směsi je rovna sumě luminiscence komponent [4].


$$\alpha_R(C) = \int_0^{\infty} S_R(\lambda)C(\lambda)d\lambda$$

$$\alpha_G(C) = \int_0^{\infty} S_G(\lambda)C(\lambda)d\lambda$$

$$\alpha_B(C) = \int_0^{\infty} S_B(\lambda)C(\lambda)d\lambda$$
(2.4)

**Rovnice 2.4 Výpočet souřadnic RGB.**

*Kde  $S_{R,G,B}$  jsou absorpční spektra třech typů čípků a  $C_{R,G,B}$  jsou spektrální distribuce příchozího záření.*



**Obrázek 2.4 Závislost normalizované absorbance na vlnové délce pro různé typy čípků.**

*Tři typy čípků bývají označovány jako S (small/blue), M (medium/green) a L (long/red) podle vlnové délky na níž jsou nejvíce citlivé. Písmeno R označuje odezvu pro tyčinky, které nejsou citlivé na barvu. Převzato a upraveno z [5] a [10].*

CIE (Commission Internationale de l'Eclairage – Mezinárodní komise barevných standardů) doporučuje pro volbu primárních monochromatických barev tři vlnové délky - 700 nm (červená); 546,1 nm (zelená) a 435,8 nm (modrá) [3]. Bohužel, jak je patrné z (Obrázek 2.4), dosažení některých barev viditelného spektra by v tomto případě bylo možné pouze při použití záporných hodnot některých primárních barev [4]. Vzhledem k tomu, že nebyl nalezen jiný soubor primárních barev, jenž by to umožňoval, vývoj byl soustředěn na definování jiných barevných soustav. Nejhojněji používaný je systém CIE (X,Y,Z), který všechny primární barvy definuje v kladné rovině, barvy jsou vyjádřeny pomocí jejich chromatičnosti v chrominančních souřadnicích. Pro účely barevné reprezentace multidimenzionálních obrazových dat (viz kapitola 2.4.2) se však spokojíme s kombinováním jednotlivých vlnových délek, bez nutnosti konverze. Více informací ohledně věrné barevné konverze hyperspektrálních dat, včetně praktických příkladů v programu MATLAB, poskytuje [9].

## 2.3 Obrazová informace

Termínem snímek je podle [8] obecně označována reprezentace reálného objektu nebo scény na určitém záznamovém médiu. Proces této reprezentace se nazývá snímání nebo zobrazování a lze pod něj zařadit i běžné techniky jako je kresba uhlím, olejová malba, fotografie, nahrávání videa atd. Umělecké zobrazování je mnohdy uskutečňováno z pouhé představy, bez reálného modelu, naopak zobrazování pro vědecké účely přírodních věd je naopak vždy vykonáváno za účelem popsání určitých parametrů zkoumaného objektu nebo scény [7]. Při zobrazování scény předpokládáme, že každá část scény má stejnou důležitost, nebo minimálně dokud určitá analýza nedeterminuje, která část je použitelná a kterou lze vyřadit. To platí například pro satelitní snímání povrchu země, kdy každý pixel obsahuje geologické vlastnosti, teplotu, vlastnictví pozemku, vegetaci, pokrývku sněhu atd. [8]. Při snímání objektů je předem známé, že studované objekty jsou jediným relevantním bodem obrazu, označovaným jako ROI (Region Of Interest, tedy oblast zájmu, viz kapitola 3.6.1) [10]. Vyřazením těchto irelevantních dat dochází k obrovské úspoře paměti i výpočetního výkonu. Zajímavým aspektem tohoto typu zobrazování je vliv kognitivní psychologie [8]. Pokud umělec zachytí štětcem třírozměrnou scénu na plátno, provádí transformaci třírozměrných dat do dvourozměrného prostoru. Spoléhá přitom na fakt, že pozorovatel je schopen zpětné transformace a může vnímat scénu jako trojrozměrnou [7]. Pozorování je tedy subjektivním procesem, který může být pro každého pozorovatele odlišný. V uměleckém kontextu je tento fakt velmi cílený a žádaný. Pro vědecké účely je naopak tento přístup nepřijatelný.

Většina zobrazovacích technik je založena na určitém typu projekce. Scéna je promítnuta skrze určitý objekt (např. optická soustava fotoaparátu) na určitý materiál citlivý na záření (fotografický papír/snímač). Projekční techniky často využívají větší množství senzorů, případně senzor s větším rozlišením, aby byly schopny detekovat záření v každém pixelu okamžitě, nebo v rychlé sekvenci, případně snímat simultánně větší počet vlnových délek. Při snímání je většinou přítomen jeden detektor, často dokonce jen jeden zdroj záření (např. laser) [7]. Předmět zkoumání je umístěn mezi zdroj záření a detektor, a je s ním pohybováno. Pomocí registrování pozice a absorpce/odrazu, je možné rekonstruovat obraz. Tento způsob skenování umožňuje lepší kontrolu příchozího záření a eliminaci objektivních chyb, vede ovšem k pomalejšímu průběhu snímání. Existují však i techniky využívající většího počtu detektorů – typicky vícero řad polovodičových diod pro liniové snímání. Rychlost skenování je vyšší a lze dosáhnout lepšího rozlišení. Typickým příkladem liniového skenování je počítačový skener. Třetí technikou zobrazování je tomografie. V klasické tomografii je měřen útlum záření skrze určitý objem (tělo pacienta) jako křivkový integrál [7]. Pomocí výpočtu dochází k rekonstruování absorpce v objemu do obrazové informace.

## 2.4 Digitální obraz

### 2.4.1 2D obrazová data – hodnoty intenzity

Dvourozměrný obraz může být popsán horizontální dimenzí  $x$ , přičemž  $x$  je prvkem reálného intervalu  $[0,a]$  a vertikální dimenzí  $y$ , jež je prvkem reálného intervalu  $[0,b]$ . 2D obraz je tedy popsán v doméně  $[0,a] \times [0,b]$  funkcí intenzity  $f(x,y)$  [7]. Parametry  $a, b$  běžně nemají stejnou hodnotu, bývají však stejného řádu. V obrazové analýze je obvykle za počátek používán levý horní roh, osa  $x$  jde zleva doprava a osa  $y$  shora dolů. Zmíněné je definováno vysílacími televizními standardy. Funkce intenzity  $f(x,y)$  popisuje intenzitu v každém bodu intervalu  $[0,a] \times [0,b]$ , funkce neexistuje mimo hranice tohoto intervalu. Je zřejmé, že tato funkce bude velmi komplexní, z tohoto důvodu dochází k digitalizaci obrazu a intervaly  $[0,a]$  pro osu  $x$  a  $[0,b]$  pro osu  $y$  jsou diskretizovány. Parametr  $x$  nabývá hodnot  $i=1,2,3,\dots,I$  a parametr  $y$  hodnot  $j=1,2,3,\dots,J$ . Funkce  $f(x,y)$  se stává maticí  $G(i,j)$  (pozn. Geladi [7] doporučuje značit matice tučně), kde  $g$  popisuje lokální zprůměrovanou intenzitu v místě  $(i,j)$ . Došlo tedy k digitalizaci původního analogového spojitého signálu a obraz je nadále ve formě dvourozměrné matice o konkrétním počtu řádků  $i$  a sloupců  $j$ , popisující prostorové souřadnice každého obrazového elementu [8]. Každý z těchto elementů je nazýván pixelem, který je považován za základní a nedělitelný stavební blok digitálního obrazu [7]. Pixely obsahují hodnotu, jež odpovídá navzorkované přijaté intenzitě v daném bodě. Číselný rozsah těchto hodnot intenzity se odvíjí od bitové hloubky, v níž ke vzorkování došlo [8]. Například běžné černobílé snímky bývají vzorkovány 8bitově, nabývají tedy  $2^8$  hodnot (0-255), přičemž nula značí nejčernější černou barvu a 255 nejbělejší bílou [8].

Zmíněná diskretizace nemusí nutně vést k vytvoření čtvercové struktury pixelů, například [7] zmiňuje i jiné alternativy jako je hexagonální systém, v němž má každý pixel šest geometricky ekvivalentních sousedů. Tento systém má určité výhody, ačkoliv počítačová implementace se ukázala jako velmi nepraktická a šachovnicová struktura čtvercových pixelů tak zůstává zdaleka nejpoužívanějším způsobem vyjádření digitální obrazové informace.

Literatura [7] důrazně doporučuje označovat tento typ dat jako snímek intenzity, snímek ve stupních šedé, jednorozměrný snímek, nebo univarietní snímek. Pro účely této práce je preferován termín snímek ve stupních šedé, nadále tedy budou tato data označována tímto způsobem.




### 2.4.2 2D obrazová data – RGB

Dvourozměrným barevným snímkem se rozumí RGB snímek, jež se skládá ze tří kongruentních snímků intenzit, popsaných v kapitole 2.4.1, přičemž každý byl nasnímaný pro jinou vlnovou délku (pro RGB jde o červenou, zelenou a modrou) – ať již použitím soustavy filtru, nebo většího počtu snímačů [7]. Tyto snímky se na základě dříve popsané teorie tristimulu (viz kapitola 2.2) míchají pro docílení finálního barevného snímku. Termín kongruence označuje podle [7] shodnost sousedních snímků, kdy dva polygony mohou být stohovány tak, aby došlo k jejich vzájemnému překryvu. Translace a rotace jsou přípustné, změna velikosti nikoliv. Dva nebo více obrazů se tedy stávají shodnými, pokud mohou být stohovány tak, že pro každý pixel jednoho obrazu existuje jeden odpovídající pixelu na jiném snímku, který odkazuje na stejnou pozici objektu nebo scény [8]. Počítačové monitory například barevný snímek zobrazují kombinováním tří 8bitových snímků ve stupních šedé. To znamená, že v takovém systému může být jakýkoliv pixel reprezentován 24 bity. Celkem tedy lze „namíchat“  $256^3$ , tedy  $16,77 \cdot 10^6$  barevných kombinací. Výsledek bývá nazýván barevným kompozitem [8]. Princip kombinování třech RGB snímků může být použit pro jakýkoliv typ obrazů, například pro rentgenové snímky, magnetickou rezonanci nebo snímky z elektronového mikroskopu a další vícedimenzionální obrazová data. Mimo simulaci reálné barvy, můžeme také přidávat umělou barvu do snímku za účelem zdůraznění určitých vlastností. To je učiněno pomocí použití barevných vyhledávacích tabulek (LUT – Color Lookup Table), umožňující uživateli definovat jakoukoliv barvu [7]. Konkrétní příklad na testovaných datech Aviris je v kapitole 7.

### 2.4.3 3D obrazová data

Technicky vzato je již RGB obraz formou trojrozměrného obrazu, většina literatury ([8], [7], [5]) tento fakt uznává, ačkoliv si termín vyhrazuje až pro multispektrální a hyperspektrální obrazovou informaci, protože RGB využívá třetí dimenze pouze pro zobrazení barvy. Tato vícedimenzionální obrazová data jsou tedy podobně jako RGB data složena z rovnoběžné struktury, stohu kongruentních snímků intenzit, rozdílem je však jejich počet – v případě multidimenzionálního obrazu mluvíme o čtyřech a více, pro případ hyperspektrálního obrazu o stu a více různých snímků intenzit. Každý z těchto snímků je samostatnou dvourozměrnou maticí, měřenou pro jinou vlastnost nebo proměnnou, obvykle vlnovou délku. Některé zdroje [5] označují jednotlivé jednorozměrné snímky (řezy hyperkrychle) za pásmové snímky, neboť se vždy váží právě k určitým frekvenčním pásmům, krokovaných v satelitních systémech (viz [11]) konstantní šířkou pásma. V případě dálkového snímání korespondují naměřená data intenzit s odraženým zářením od určitého regionu, typicky od povrchu Země, jde tedy o radianční data zemského povrchu [5].


Třetí dimenze bývá popisována indexem  $k$  a trojrozměrná matice by měla podle [7] být doplněna o dolní vodorovný pruh, tedy  $\underline{G}$ . Každý element této matice (nadále označovaný termínem voxel, zkratka volumetric pixel, tedy objemový element [11]), je jasně definován pozicí  $g_{ijk}$ . Popsaný trojrozměrný stoh kongruentních snímků intenzit bývá také velmi často označován za datovou krychli (data cube [8],[7]), nebo hyperkrychli (hyper cube [12]). Další významnou definicí hyperspektrální datové informace a způsob jejího odlišení od multispektrální je podle [8] fakt, že data třetí dimenze pro každý pixel tvoří téměř spojité spektrum. Matematické vyjádření trojrozměrného obrazu probíhá dle [8] analogicky jak bylo popsáno v kapitole 2.4.1, přibývá ovšem třetí dimenze. Indexy  $x,y$  a  $z$  tedy tvoří doménu založenou na funkci  $f(x,y,z)$ , jež je prvkem intervalů  $[0,a]$  pro  $x$ ;  $[0,b]$  pro  $y$  a  $[0,c]$  pro  $z$ . Pro záznam diskrétních hodnot jsou indexy transformovány jako  $i=1,2,3,\dots,I$ ;  $j=1,2,3,\dots,J$ ;  $k=1,2,3,\dots,K$ . Diskrétní funkce intenzity přechází v  $g(i,j,k)$  a datová matice v paralelní strukturu (kvádr/krychli, viz Obrázek 2.6).



**Obrázek 2.5 Grafické porovnání jednorozměrného, RGB a hyperspektrálního snímku obrazových dat.**

*(i,j) jsou souřadnice reprezentující pozici pixelu v prostorové dimenzi, k je počet řezů spektrální dimenze.*

Pokud je v obrazových datech přítomno více vlnových délek než 3 (RGB), přímá barevná interpretace již není možná. Může však dojít k vytvoření tzv. „pseudobarevného obrazu“ – jsou zvolena frekvenční pásma, jež nejbližší odpovídají vlnovým délkám RGB a tímto způsobem dochází k vytvoření barevného kompozitu. Výsledný obraz se jeví jako barevný, avšak míra, jak moc je takto vytvořený obraz podobný skutečnosti, záleží na správné volbě spektrálních kanálů. Například [13] doporučuje pro získání RGB náhledů dat hyperion použít vlnové délky 641 nm, 580 nm a 509 nm, případně sousední kanály, blízké těmto vlnovým délkám. Zároveň [13] popisuje další možnosti konstrukce náhledů pro jiné účely – například VNIR (Visible and Near-Infrared, tedy viditelné a infračervené frekvenční pásmo) Vegetation RGB a NDVI (viz Obrázek 3.3) pro detekci vegetace a SWIR (Short Wave Infrared, tedy krátkovlnné infračervené frekvenční pásmo) RGB (viz Obrázek 7.3). Výběr konkrétních vlnových délek se však v literatuře velmi různí, například oficiální příručka dat Aviris (viz kapitola 7.2) [14] i příručka software TNTmips (viz kapitola 7.3.2) [12] doporučují manuální kalibraci těchto pásem tak, aby vyhovovala potřebám uživatele a zároveň ho povzbuzují k úpravám jasu a ekvalizaci histogramu.



Obrázek 2.6 Trojrozměrná datová struktura, tzv. hyperkrychle hyperspektrálního obrazu.

Alternativní způsob nahlížení na hyperspektrální data zmiňuje [5], spočívá v nahlížení dat na stejné lokaci (stejný pixel, tj. stejné souřadnice v prostorové dimenzi) a tím pádem vytvoření vícedimenzionálního pixelového vektoru. Každý element tohoto vektoru koresponduje s odraženou energií určité vlnové délky od určitého povrchu nebo předmětu (dálkové snímání – povrch Země). Pokud jde o povrch Země, všechny pixelové vektory, ze kterých se tato hyperspektrální data skládají, budou vykazovat určitou míru korelace, vzhledem k vlastnostem absorpce energie zemskou atmosférou. Například všechny vektory budou vykazovat charakteristickou redukci energie na frekvencích, kde je elektromagnetická energie absorbována vodou v atmosféře [12] (viz kapitola 7.3.4). Věda se hyperspektrálními daty a jejich zpracováním zabývá již bezmála 25 let, stále však tato oblast zůstává ne zcela vyřešená. Zpracování těchto dat totiž skýtá mnoho překážek, které jsou těžko překonatelné, jak zmiňuje [15]. Hlavním problémem je komplexnost těchto dat a jejich následné vědecké použití, které vylučuje příliš vysoké zkreslení.

#### 2.4.4 4D a vícerozměrná obrazová data

Přechodu do další dimenze můžeme dosáhnout například pokud necháme objem rozvíjet se v čase. V tomto případě může jít například o dlouhodobé monitorování zdravotního stavu pacienta [8]. Pro tento případ byl navržen podle [7] termín tixel (time-integrated element – element integrovatelný v čase). Dále je možné vytvořit pseudo-4D pomocí stohování trojrozměrných objemů podél čtvrtého fyzikálního parametru (například teploty, pH, hustoty). Literatura [7] poukazuje na podobnost principu 3D a 4D nukleární magnetické rezonance (NMR). Pro účely dálkového snímání se tento postup také využívá, například pro dlouhodobé monitorování zalesnění či úbytku ledovců [14], je však nutné tato data nejprve správným způsobem připravit (translace, rotace, škálování – viz kapitola 2.5.4), aby došlo ke shodě v prostorové dimenzi snímku.

## 2.5 Parametry digitálních obrazových dat

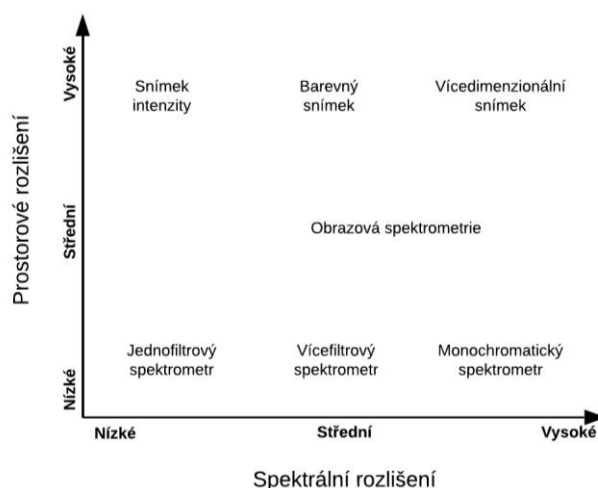
### 2.5.1 Rozlišení prostorové dimenze

Diskretizace obrazu vytváří limitace v prostorovém rozlišení. Funkce  $f(x,y)$  popisuje analogový obraz ve spojitě bázi  $x,y$  na intervalech  $x \in [0,a]$  a  $x \in [0,b]$ , tedy obdélník jeho kartézským produktem [7]. Vzhledem k tomu že  $x \in [0,a]$  a  $x \in [0,b]$  jsou reálná čísla, po jakémkoliv dělení může následovat další dělení na ještě menší části [7]. Tato vlastnost reálných čísel má jen teoretickou hodnotu, protože je obvykle limitována chybou po zaokrouhlení. Populárními hodnotami rozlišení, neboli jinak řečeno počty řádků a sloupců, jsou 256, 512, 1024, 2048 a 4096. [7] Mocniny čísla 2 nejsou vyžadovány, avšak dochází tak k lepšímu využití architektury paměti počítače. Pokud není obrazová informace ve formě obdélníků, bývají zbylé plochy doplněné nulami, což usnadňuje další analýzu a zpracování. [8] dále upozorňuje na minimální počet řádků a sloupců, při jehož překročení se vytratí dojem obrazu a ten se stane pouhou kolekcí čtverců. Zmizí detaily, objeví se zubaté kontury a šachovnicová struktura obrazové informace se stane velmi zřejmou. Tento limit leží v intervalu 32 a 64, přesná hodnota závisí subjektivně na pozorovateli a zároveň na snímané scéně nebo objektu, protože určité objekty si zachovávají svůj vizuální dojem lépe než jiné. Výhodou nižšího rozlišení jsou nižší nároky na paměť a výpočetní výkon pro analýzu, nevýhodou je menší míra detailů.

### 2.5.2 Rozlišení intenzity

Podobné principy platí i pro funkci intenzity  $g(i,j)$ . Vzorkovaná spojitá funkce  $f(x,y)$  obsahuje nekonečné množství hodnot intenzit [7]. V praxi samozřejmě dochází při diskretizaci k určitým chybám po zaokrouhlení. Kromě těchto malých chyb dochází ke zkreslení šumem při měření a dalším technickým limitacím, což ovlivňuje horní mez rozlišení  $g(i,j)$  – od určité hodnoty rozlišení nedochází ke zpřesnění dat. Existuje také mnoho rozdílných způsobů, kterým počítač může uložit a pracovat s čísly, což také vytváří určité bariéry a omezení pro digitalizované obrazy. Například program MATLAB zpracovává obrazovou informaci ve formátu double (64bitovém), int16/uint16 (16bitovém), nebo int/uint8 (8bitovém) [16]. Některé publikace, například [17] uvádějí rozlišení intenzity jako bpp (bits per pixel) – zejména pro srovnání kompresních metod. Běžné spotřební počítačové monitory bývají limitovány 8bitovým rozsahem, tiskárny 16bitovým. Existuje velké množství individuálních rozdílů závislých na počítači, operačním systému, nebo například na použitém programovacím jazyku. Vzhledem k tomu, že počítače pracují pouze s binárními čísly, je přirozené, že pro vyjádření intenzity využívají v drtivé většině případů mocniny čísla 2. Dochází však i k využití komplexních čísel, a to zejména u výpočtů, jež souvisejí s Fourierovou transformací [7].

Pro použití dat v dalších matematických výpočtech a analýzách doporučuje [7] zachovat formát double nebo floating point, pro účely pouhé vizualizace je vhodnější zkrátit data na celá čísla, což má za následek úsporu paměti. Důležitou skupinou obrazů jsou také binární obrázky, jež mají úroveň intenzity nabývající hodnot pouze 0 a 1. Často mohou být podle [7] použity pro reprezentování logických situací, příkladem čehož může být klasifikace a detekce objektů na pozadí – krajina může být černá a objekty bílé pixely. Tohoto typu binárních dat se používá pro data ground-truth (data nasnímaná blízko povrchu – pro účely kalibrace budoucího vzdáleného snímání atd.) [18].



Obrázek 2.7 Porovnání rozlišení spektrální a prostorové dimenze pro různé metody snímání.

### 2.5.3 Rozlišení spektrální dimenze

Rozlišením spektrální dimenze je označován počet spektrálních pásem, jež byla nasnímaná. Pro dálkově nasnímané hyperspektrální snímky bývá typicky snímáno zhruba 200 až 300 vlnových délek, tato hodnota tedy reprezentuje rozlišení spektrální dimenze. Menšího rozlišení dosahují například multispektrální fotoaparáty [9] nebo specializované systémy dálkového snímání, například satelit Sentinel [19], zmíněné případy mají spektrální rozlišení 33, resp. 13 vlnových délek. Požadované rozlišení je definováno dle potřebného využití. V mnoha případech dochází ke kompromisu mezi spektrálním a prostorovým rozlišením, pokud by bylo vyžadováno obojí, byla by data extrémně objemná a jejich zpracování velice náročné. Proto například spektroskopie využívá bodové spektrometry o extrémně vysokém spektrálním rozlišení, avšak nulovém prostorovém rozlišení (viz kapitola 3.2). Naopak satelitu pro detekci infrastruktury bude stačit nasnímaných několik vlnových délek, avšak s vysokým rozlišením prostorové dimenze. Zdroj [20] porovnává rozdíl mezi dvěma senzory, snímající stejnou scénu – jeden se spektrálním rozlišením 256, resp. 3648 vlnových délek a za použití interpolačních a decimačních technik srovnává rozdíly v nasnímaných spektrálních průbězích.

## 2.5.4 Matematické operace – předzpracování

V kapitole 2.4 již bylo řečeno, že digitální obrazová data jsou na počítačových pamětech uložena v podobně řad čísel, reprezentujících obrazové matice. V této formě mohou být podrobeny velkému množství matematických operací. Tyto operace mohou podle [21] probíhat jednak v rámci jednoho konkrétního snímku (intra frame) nebo v rámci několika následujících snímků (inter frame). Touto sérií snímků může být myšlen například videozáznam, tedy zachycení vývoje obrazové informace v čase nebo vícerozměrný snímek a operace na sousedních pásmech vlnové délky. Vezmeme-li v úvahu speciální případy, jako jsou satelitní a lékařská zobrazování, můžeme uvažovat aplikaci inter frame operací například na dva snímky, pořízené s jistým časovým odstupem [21]. Na satelitních snímcích lze tak sledovat například rozvoj vegetace na určitém území, na lékařských snímcích vývoj nemoci, dochází tak k vytvoření 4D, nebo vícerozměrné matice (viz kapitola 2.4.4).

Mezi intra frame operace patří například změna kontrastu, korekce stínování, korekce chyb, redukce dat, komprese dat, detekce textury, geometrická transformace, statistická analýza a detekce pohybu [7]. V oblasti satelitního snímání patří mezi typické intra frame operace korekce zisku zesilovače (úprava jasu), korekce kontrastu, korekce offsetu a kalibrace reflektance. Příručka [11] varuje, že tyto operace je vhodné provádět ve stejné míře na celém datovém souboru. Není možné například možné zvýšit jas pouze na oblasti NIR, aniž by došlo k nevratnému zkreslení nasnímaného spektra vlnových délek.

Inter frame operace na sérii souvisejících snímků jsou například geometrické srovnávání, srovnávání intenzit, snímková algebra (image algebra) a boolova algebra [7]. Některé tyto operace se shodují s operacemi intra frame z minulého odstavce, rozdíl je však v jejich aplikaci – ta může probíhat nelineárně, například spektrální korekce na základě definované křivky. Příručka [11] popisuje postup těchto operací a přístup k daným metadatům pro snímky Aviris. Přesné matematické operace popisuje [7], poukazuje na možnost obrovské úspory paměti i výpočetní náročnosti po redukování vstupních dat. Redukci dat zdroj dělí na redukce korekcí, vektorem a skalárem. Redukce korekcí může být aplikována například tím způsobem, že dojde k začlenění binárního obrazu, jenž specifikuje oblast zájmu (začerněné oblasti jsou mimo tuto oblast, bílé oblasti jsou součástí). Jde tedy o způsob využití alfa kanálu, který známe z analýzy běžných obrazových dat a videozáznamů [22]. Redukcí vektorem se rozumí například korekce stupňů šedé histogramem a redukcí skalárem se rozumí přímé odstranění dat mimo zájem – může jít například o hraniční limit buněčných jader, jenž jsou detekována na mikroskopickém snímku – další jádra již nebudou detekována, dochází tedy k cílené redukci [7].

Filtrační metody, zmíněné v předchozím odstavci, je možné dále dělit dle toho, jestli po filtraci dochází ke změně prostorového rozlišení, nebo rozlišení intenzity [7]. Bodové operace jsou například aplikovány pouze na rozlišení intenzity jednoho snímku – s každým pixelem je operováno bez uvažování obsahu sousedních pixelů. Extrémním případem tohoto může být již zmíněná aplikace binárního snímku, pak mluvíme o segmentaci. Jiným přístupem jsou aplikovány lokální filtrační operace – výsledná hodnota pixelu závisí i na některých, případně všech okolních pixelech. Hranice této lokality bývají typicky  $2 \times 2$  až  $25 \times 25$  (px) [7], patří mezi ně například mediánová redukce šumu, filtry dolní a horní propusti a gradientní filtrace. Další skupinou je globální transformace, kterou charakterizuje, že každý výstupní pixel obsahuje určitou míru informace o pixelech na vstupu, zahrnuje se mezi ně například Fourierova a Hadamardova transformace, a použití nalézají například při dekonvoluci, filtračním filtrování, chybové korekci a podobně [7]. Dále můžeme zmínit geometrické transformace, jež jsou převážně realizovány v prostorových souřadnicích i a j určitého obrazu. Může jít o rotace, zrcadlení, roztahování, nebo smršťování. Někdy je vyžadována interpolace intenzit. Geometrické operace jsou často začleněny pro dosažení lepší shody mezi dvěma obrazy stejné scény nebo objektu, k jejichž srovnávání má dojít. Příkladem může být rentgenový snímek, nebo snímek magnetické rezonance člověka – ten může být pořízen například v jiném úhlu [7]. S podobným případem se setkáváme u satelitních dat, pokud bývá zachována orientace světových stran a let samotný měl diagonální trajektorii – na snímku pak dochází k vytvoření černých míst, neobsahující žádná použitelná data. Operace na větším počtu obrazů bývají v algebraickém tvaru, geometrickém tvaru, případně kombinace obojího. Při zpracování binárních snímků se využívá Booleova algebra [7].

Analýza obrazové informace je úzce spjatá s matematickými i statistickými disciplínami. O datové analýze a předzpracování hovoříme, pokud jsou vstupní data transformována do nových dat. Příkladem může být vytvoření statistických parametrů, popisujících distribuci datového souboru. Analýzou se rozumí výsledek určité operace, jež byla uskutečněna za účelem dosažení určitého závěru (například analýza špatně detekovaných snímků za účelem jejich odstranění) [7]. Předzpracování (processing) se využívá, pokud jsou výsledkem transformovaná data, jež je potřebné využít pro další výpočty. Rozdíl mezi těmito termíny je tedy prostý – analýza přímo vede k závěrům, předzpracování vede k dalšímu zpracování nebo analýze.

### 3. Hyperspektrální a multispektrální obrazová data

#### 3.1 Využití hyperspektrálního zobrazování

Hyperspektrální zobrazování vděčí za svůj vývoj zejména potřebám satelitního a leteckého snímání, společně označovaného jako vzdálené, nebo dálkové snímání (remote sensing). Dalšími milníky pro rozvoj systematického využití většího množství vlnových délek byl například rozvoj elektronové mikroskopie a možnost detekce většího množství vlnových délek rentgenového záření [8]. Postupně se tak však rozšířilo i do různých odvětví průmyslu a služeb [12]. V botanice se využívá pro detekci variací osiva – nemocí, vad a defektů; sladování; klíčení a hydratace [7]. S botanickým využitím úzce souvisí potravinářství, jež kontroluje kvalitu a kontaminaci. Farmacie detekuje falešná léčiva, celistvost obalů tablet, a především pak homogenní promísení složek v konečném produktu. Strojní průmysl využívá detekce vad, koroze a posuzování ryzosti. Ve forenzních vědách a patologii pak hyperspektrální zobrazování nalézá využití pro analýzu otisků prstů, tělních tekutin, ověřování pravosti dokumentů, hledání stopového množství sloučenin a detekci patogenů [7]. Přímé využití dat vzdáleného snímání Aviris uvádí [14]. Používají se například pro výzkum atmosféry (parametry oblak, koncentrace vodních par a aerosolů), ekologii (míra hydratace, koncentrace ligninu, chlorofylu, celulózy, pigmentů, mapování vegetačních druhů), geologii (mineralogie, detekce půdních typů), analýzu vodních ploch (obsah chlorofylu, planktonu, organických složek, sedimentů, konstituce dna, batymetrie), sněhovou hydrologii (míra zasněžení oblasti, velikost zrna, nečistoty a tání), detekci environmentálních hrozeb (přímá a nepřímá kontaminace), analýzu hoření biomas (subpixelové teploty, kouř a produkty hoření), či pro komerční výzkumy (nalézání ložisek minerálů a drahých kovů, stav lesních a zemědělských oblastí).

Využití hyperspektrálního zobrazování pro studium starožitného porcelánu zmiňuje [7]. Tento porcelán býval zdoben vrstvením barev, hyperspektrální zobrazování umožňuje analýzu těchto vrstev a poskytuje tak bližší informace o postupu výroby. Příklad, tentokrát z biologie uvádí opět [7] a týká se detekce vegetace v rašelině. Malé množství rašeliny je vyvařeno v ředěném hydroxidu sodném – tím dojde k odstranění huminových kyselin a koloidních částic. Následně dochází k vytvoření histogramů vegetačních tříd vizuální inspekci materiálu pod mikroskopem. Tyto histogramy mohou být dále použity při studování původu a historie (stupně rozkladu). Hyperspektrální zobrazování nalézá využití i v oblasti stavebnictví. Pro tyto účely využívá na stavební fakultě ČVUT Ing. Eva Matoušková senzory Headwall VNIR A Series a bodový spektrometr Ocean Optics. Její práce aktuální práce spočívá v analýze a detekci středoevropských omítek, dříve publikované práce se týkaly neinvazivní analýzy maleb [23], nebo analýzy a monitorování archeologických nalezišť [24], [25].



## 3.2 Spektrometrie a spektroskopie

Mezi spektroskopií a spektrometrií je značný rozdíl, ačkoliv je převážně populární literatura často zaměňuje. Spektroskopie v doslovném překladu znamená „dívání se na spektrum“ [7] – tento termín je tedy vhodný používat pro případy, kdy je spektrum studováno vizuálně, například pro lokalizaci maxim a identifikaci chemických struktur. Spektrometrie znamená v překladu „měření spektra“, termín je tedy vhodné používat při sběru dat pomocí výpočtu chemických nebo fyzikálních vlastností.


Spektroskopie se tedy zabývá studiem interakce hmoty a elektromagnetického záření. Historický původ této vědní disciplíny souvisí se studiem viditelného světla a jeho disperzi na jednotlivé vlnové délky po průchodu hranolem [26]. Později byl tento koncept rozšířen tak, aby zahrnoval veškerou interakci záření jako funkci vlnové délky nebo frekvence. Spektroskopická data jsou běžně reprezentována emisním spektrem. Spektrální zobrazování je jakýmsi hybridem samostatných oborů zobrazování a spektroskopie. Výsledek spektroskopického měření bývá elektromagnetické spektrum, měřené v jednom bodě. Tato spektra jsou využita pro odvození informace o spektrálních otiscích – produktu interakce hmoty a elektromagnetického záření [14]. Monochromatický obraz se obvykle skládá z matice většího množství pixelů, každý pixel však obsahuje informace pouze o jedné naměřené vlnové délce, RGB obraz oproti monochromatickému obsahuje tři vlnové délky (viz kapitola 2.4). Spektrální obraz kombinuje vše zmíněné – jde o matici pixelů, přičemž každý pixel obsahuje vlastní elektromagnetické spektrum (velmi mnoho vlnových délek). Zmíněné je demonstrováno (Tabulka 3.1), (Obrázek 3.2) a (Obrázek 3.1).

Spektroskopie je přínosná například v potravinářství a zemědělství. Testovaný subjekt (zelenina, ovoce nebo osivo) je vystaven viditelnému světlu, přičemž jen zhruba 4% záření je přímo odraženo subjektem na jeho vnějším povrchu a zbytek je absorbován subjektem. Většina energie absorbovaného záření pronikne pouze malým objemem a subjekt opouští blízko místa vzniku. V okamžiku, kdy světlo pronikne do subjektu hlouběji, je ovlivněno rozdíly v délce cest a rozdílnými absorpcemi sloučenin – to vede nejen k barevnému vjemu, jež vnímá pozorovatel, ale zároveň k informaci o chemickém složení materiálu (chemické vazby absorbují různé vlnové délky, naměřené spektrum tedy reflektuje informace o složení) [8]. Důsledkem toho lze podle spektrálních průběhů rozeznat rozdílné minerály, plodiny, ale i třeba typ plastů, nebo zralost ovoce [11]. K těmto účelům lze úspěšně použít spektroskopii, avšak měřením v jednom bodě získáváme informaci bez prostorového rozlišení, máme tedy informace pouze o konkrétním bodě, nikoliv o celém subjektu. Tento neduh řeší spektrální kamery (Obrázek 3.2), jež jsou schopné akvizice na velkém počtu vlnových délek, nemusí tedy nutně docházet ke kompromisu mezi spektrálním a prostorovým rozlišením.

Obecný tvar spektra dálkově snímaných dat je obvykle dominován křivkou slunečního záření, ovlivněnou absorpčními vlastnostmi zemské atmosféry [14]. Zářící vlastnosti Slunce odpovídají záření absolutně černého tělesa [14], spektrum obsahuje maxima v zelených vlnových délkách a minima na nízkých a vysokých kmitočtech. Atmosféra absorbuje světlo na vlnových délkách, jež korespondují s absorpčními vlnovými délkami komponent atmosféry – kyslíku, dusíku, oxidu uhličitému, vody a dalších elementů. Největší minima by měla být přítomná kolem vlnových délek 1 400 a 1 900 nm [11] (ověřeno viz Obrázek 3.2 a kapitola 7.3.3). Další maxima a minima mimo tyto zmíněné případy odhalují chemické složení materiálu, jež byl nasnímán. Každá substance má svou vlastní unikátní spektrální stopu – například zelené rostliny používají barvivo chlorofyl k absorpci viditelného světla, naopak odráží infračervenou část spektra. Tato vlastnost způsobuje ve spektru velký skok při přechodu vlnových délek právě do infračervené oblasti. Energie v elektromagnetice a radiaci nabitých částic je často vyjádřena v keV ( $1\text{eV}=1,602\cdot 10^{19}\text{ J}$ ), v cyklech za sekundu (Hz), nebo ve vlnové délce (m) (viz Rovnice 3.1).

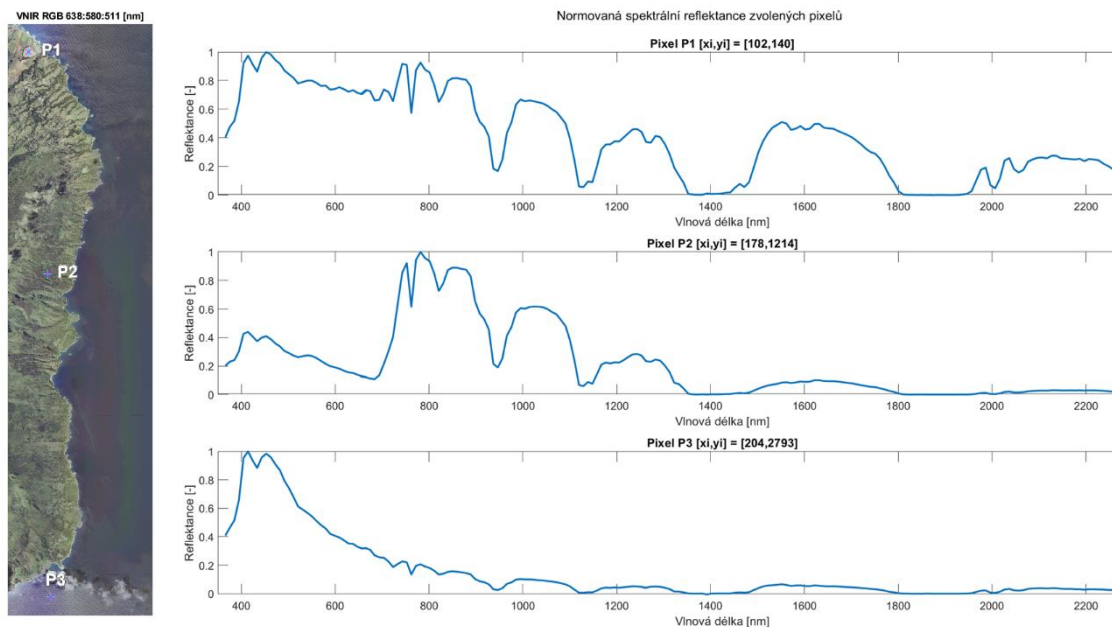
	Spektrální informace (chemické složení, fyzikální vlastnosti aj.)	Prostorová informace (větší množství pixelů v souřadnicovém systému)
<b>Spektroskopie</b>	ANO	NE
<b>Klasické zobrazování</b>	NE	ANO
<b>Spektrální zobrazování</b>	ANO	ANO

Tabulka 3.1 Srovnání spektroskopie, klasického zobrazování a spektrálního zobrazování.



Obrázek 3.1 Odraz záření na povrchu pevného prášku.

Příchozí radiace ( $I_0$ ) dopadá na povrch pevného prášku, určité množství záření pronikne povrchem a je absorbováno ( $I_A$ ), určité množství radiace projde sérií odrazů a absorpcí a je odraženo zpátky od pevného materiálu. Odraz je polokulovitý ve všech směrech, intenzita distribuce nicméně nutně nemusí být uniformní. Zobrazená rovnice ukazuje, jak může být vypočítána pseudo-absorpce ( $A$ ). Toto je nejčastější situace při zobrazování, kdy je  $I_0$  vstupní (sluneční) světlo a část  $I_R$  je snímáno fotografickým médiem nebo videokamerou. Zdroj [7].




Obrázek 3.2 Normovaná spektrální reflektance, naměřená na konkrétních pixelech zkoumaných dat Aviris.

$$E = h \cdot \nu = h \cdot \frac{c}{\lambda} \quad (3.1)$$

Rovnice 3.1 Vztah energie, frekvence a vlnové délky.

Kde  $E$  je energie fotonu (J),  $\nu$  je frekvence vlnění (Hz),  $\lambda$  je vlnová délka (m),  $h$  je Planckova konstanta a  $c$  je rychlost světla ve vakuu.



Obrázek 3.3 NDVI dat zkoumaných v kapitole 7.4.


### 3.3 Akvizice hyperspektrálních dat

Akvizice hyperspektrálních dat byla nastíněna již v jejich úvodním popisu v kapitole 2.4.3. Globálně se však dá podle [7] akvizice rozdělit na dva typy – první obsahuje prvek, který má za úkol separaci vniknuvšího světla na jednotlivé vlnové délky (disperze je docíleno pomocí soustavy filtrů, většího počtu snímačů, nebo štěrbin); druhý typ používá množství monochromatických zdrojů světla, které přímo produkují požadované vlnové délky. Nás pro účely dálkového snímání dat více zajímá první způsob. Jedním z konkrétních způsobů je spektrofotometr, skládající se ze světelného zdroje, monochromátoru nebo soustavy filtrů pro disperzi světla do subkanálů vlnové délky, dále vzorkovací jednotky, systému detekce, digitalizace a úložiště. Nejčastějším zdrojem NIR záření jsou tungsten halogenové lampy, nebo lampy s xenonovým plynem [8]. Světlo emitující diody a nastavitelné lasery jsou také použitelné pro osvětlení méně širokopásmovými kanály. Pro širokospektrální zdroje je možné zvolit spektrální kanály na základě filtrů pásmových propustí, založených na jednoduchých interferenčních filtrech, filtrech s laditelným tekutým krystalem (LCTFs), opto-akustickým filtrem (AOTFs), nebo můžeme použít disperzi spektrální energie pomocí mřížkovacího zařízení, nebo soustavy filtrů hranol-mřížka-hranol (PGP filtr, neboli Prism-Grating-Prism).

Design spektrometrické kamery pro snímání hyperspektrálního obrazu obsahuje komponenty, které byly zmíněny výše, spolu s dalším hardwarem, který je nutný pro získání informace o prostoru (viz kapitola 6). Prostorová informace je získána přímo z měření spektrometrickou optikou, kontrolovaným pozicováním vzorku, nebo kombinací obojího. Běžně se používají tři základní typy konfigurace kamery. Tyto konfigurace se volí na základě typu získané informace o prostoru – bodový scan, liniový scan, nebo rovinný (plošný) scan [7].

### 3.3.1 Bodová akvizice

Bodový sken hyperspektrálních dat probíhá dle schématu na obrázku (viz Obrázek 3.4). Tento způsob se nejvhodněji aplikuje při získávání spektra na malé ploše (malého subjektu pozorování). Dochází totiž k repozicování vzorku, pomocí XY motorizovaného repositionálního aparátu a to před získáním každého dalšího spektra – pro každý jednotlivý pixel zvlášť [27]. Tímto dvoudimenzionálním repositionáním je postupně získán kompletní hyperspektrální obraz. Osvícování právě skenovaného pixelu obvykle probíhá pomocí velice malých sond, jež jsou zároveň identifikačním prvkem těchto systémů [27]. Systém bodové akvizice vyžaduje důkladnou kalibraci přístroje pro vlnové délky, reflektanci přístroje i přesnosti repositionálního aparátu před samotným pořizováním hyperspektrální informace. Další nevýhodou je limitace velikosti skenovaného objektu a rozlišení prostorové dimenze, jež se odvíjí právě od velikosti repositionálního aparátu a minimálního kroku. Pramen [27] doporučuje využití bodového skenování pro zkoumání malých předmětů v potravinářství, biologii a chemii.

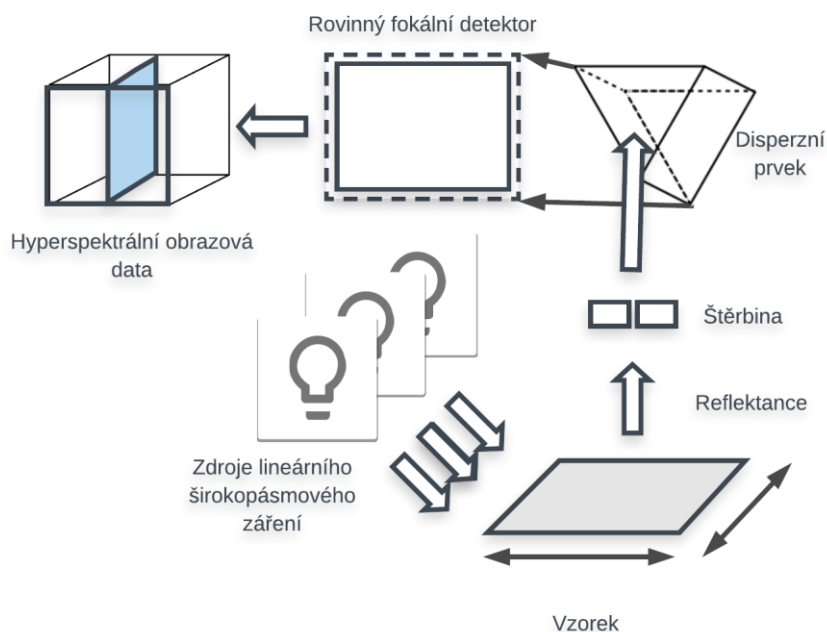


Obrázek 3.4 Bodová akvizice hyperspektrálních dat.

Pozn. schéma navrženo podle [8].

### 3.3.2 Liniová akvizice

Druhý přístup konfigurace kamery je založený na liniovém skenování, označovaném v literatuře [5],[7],[27],[8] jako pushbroom method, volně přeložitelné jako smetáková metoda (viz Obrázek 3.5). Tato metoda využívá dvoudimenzionálního detektoru, který je pozicován kolmo ke snímanému vzorku. Ten je snímán pomocí úzké linie záření dopadajícího na vzorek nebo úzké štěrbině v optické cestě vedoucí k detektoru. Hyperspektrální obrazy jsou jednoduše vytvořeny sběrem setů těchto matic, získaných pozicováním skenovací linie. Vzhledem k tomu, že není potřeba žádných filtrů, rychlost sběru dat je limitována pouze tím, jak rychle je schopná samotná kamera sbírat vzorky. Komerčně využívané přístroje jsou dostupné se snímkovací frekvencí 90 Hz a vyšší s rozlišením  $256 \times 320$  pixelu InGaAs (arsenid galito-inditými) senzory. Tato vzorkovací frekvence umožňuje získání hyperspektrálního obrazu v rámci několika sekund [8]. Liniová akvizice je nejpoužívanější, k využití dochází od vzdáleného snímání dat v satelitech a na palubách letadel, přes detekce v potravinářském průmyslu nebo v třídírnách odpadu. Například [28] navrhuje systém detekce přítomnosti fekálií v tělech mrtvé drůbeže pro využití na jatkách a [29] podává důkladné výsledky testů podobného systému pro hodnocení kvality potravin.

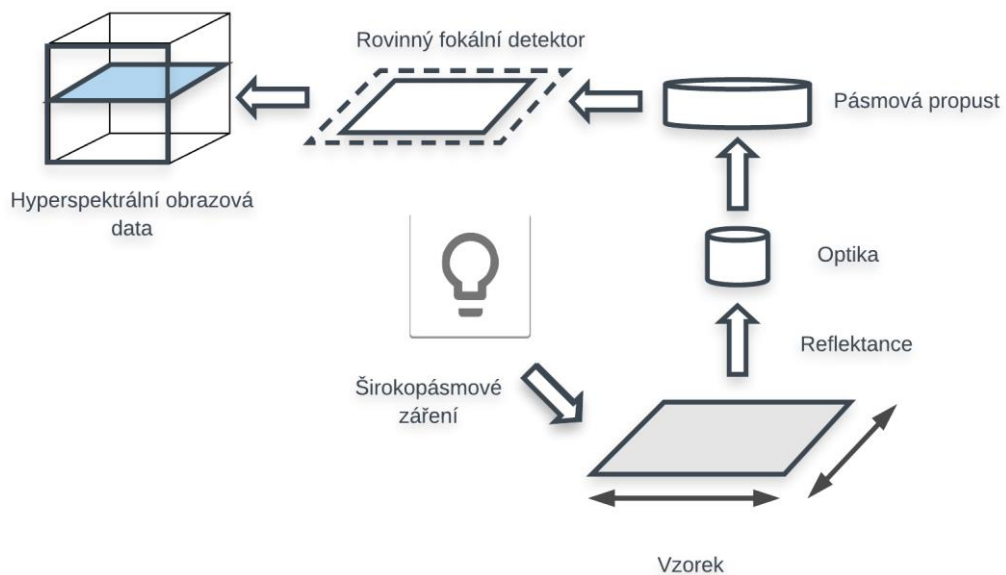


Obrázek 3.5 Liniová akvizice hyperspektrálních dat.

Pozn. schéma navrženo podle [8].

### 3.3.3 Plošná akvizice hyperspektrálních dat

Plošná akvizice hyperspektrálních dat (viz Obrázek 3.6) pozicuje detektor vůči zkoumanému vzorku v rámci rovnoběžných rovin. Vzorek je snímán na ohniskové rovině detektoru nebo čočce objektivu [8]. Spektrometrické komponenty (včetně vzorku) jsou fixovány v jedné pozici relativní k detektoru. Pokud jsou použity, musí dojít k rotaci interferenčních filtrů do potřebné pozice pro každý řez obrazu. U LCTFs a AOTFs dochází ke změně filtru automaticky a je možné použít více vlnových délek. Nevýhodou je poměrně dlouhá doba přípravy aparátu, vzhledem k častým změnám filtrů a pohybu v samotném vzorku. Nevhodná je proto například pro biologické účely, protože vzorky mohou být citlivé k teplu, jež zdroje NIR záření většinou produkují.



Obrázek 3.6 Plošná akvizice hyperspektrálních dat.

Pozn. schéma navrženo podle [8].


### 3.4 Distribuce Hyperspektrálních dat

Distribuce hyperspektrálních dat je velmi obsáhlou a komplikovanou oblastí, řešící mnoho překážek pramenících z povahy těchto dat. Po získání dat bude informace buďto uložena v zařízení, nebo přímo odeslána. Přímé odeslání obvykle vyžaduje konstantní datový tok – tento požadavek může být zmírněn zařazením paměťových bufferů. Odeslání, které probíhá v zašuměném prostředí vyžaduje kódování. Kompresi i redundanční kódování mohou být kombinovány do jedné operace užitím tzv. „joint source and channel coding“. Pokud je snímající zařízení ve vesmíru, veškeré zpracování je limitováno komplexitou [15]. Jakmile je signál přijat na Zemi, je přesunut po kabelové síti a uložen pro budoucí použití. V této fázi zpracování jsou podmínky komplexity mnohem volnější. Může proběhnout krok transkódování pro udržení dat ve více praktickém formátu. Nicméně v některých situacích je žádané, aby zpoždění mezi přijetím signálu a finálním produktem bylo co nejmenší [15]. Příkladem distribuce může být systém Aviris, jež je vybaven datovým úložištěm, z něž jsou data manuálně sbírána po každém letu, není tedy potřeba přímého odesílání (viz kapitola 6).

### 3.5 Hyperspektrální zobrazovací systémy

Existuje více způsobů, jak vytvořit spektrální snímky. Cílem je pořídit snímky pro separátní vlnové délky, toho se v praxi docílí buďto přítomností filtrů nebo velkého počtu snímačů, každého kalibrovaného pro jinou vlnovou délku (viz kapitola 0). V prvních multispektrálních kamerách byl přítomen spektrální filtr nebo laditelné filtry s tekutými krystaly LCTF, umístěné před kameru. Nyní se místo nich používají spektrografy [7]. Například satelit Hyperion využívá pro akvizici hyperspektrálních dat dva spektrometry, jeden VNIR a druhý SWIR. Samotný snímací aparát se skládá ze tří fyzických jednotek. První jednotkou je HSA (Hyperion Sensor Assembly – snímač), druhou HEA (Hyperion Electronics Assembly – podpůrná elektronika) a třetí je CEA (Cryocooler Electronics Assembly – kryogenní chlazení). Obraz země prochází do satelitu štěrbinou, která definuje okamžité zorné pole ( $0.624^\circ$  široké, tedy 7,65 km šířka pokosu v nadmořské výšce 705 Km n. m.). Po průchodu štěrbinou záření naráží na dichroický filtr. Ten je upraven tak, aby propustil vlnové délky od 900 do 2500 nm do SWIR spektrometru a odrazil pásmo vlnových délek od 400 do 1 000 nm do VNIR spektrometru [13]. HSA se skládá ze skříně, která poskytuje termální ochranu pro OMS (Opto-Mechanical Subsystem – optomechanické podsystémy), na kterých jsou umístěny VNIR a SWIR ohnisková pole. OMS samotný se skládá z teleskopu, VNIR a SWIR spektrometru. HSA je tedy přímo spojen s konstrukcí satelitu a zároveň slouží jako montážní rozhraní pro další prvky. Dále je HSA opatřen motorizovaným krytem apertury.






Obrázek 3.7 Náskres elektroniky satelitu Hyperion.

Zdroj [13].

Snímač Aviris, provozovaný NASA, je umísťovaný na letadlo, ktoré s ním preletá nad zkoumanými oblastmi. Použitý spektrometr je rozdelený na niekoľko častí – kremíková (*Si*) časť pro viditelné spektrum, arsenid galito-inditá (*InGaAr*) pro NIR a antimonid india (*InSb*) pro SWIR. Detektory jsou chlazeny tekutým dusíkem [30].



Obrázek 3.8 Schéma snímače Aviris.

Zdroj [32].

## 3.6 Předzpracování hyperspektrálních dat

Některé prameny, například [7], označují za multidimenzionální obraz už i matice, složené z třech kongruentních (shodných) snímků intenzit. Nejmenší možná obrazová multidimenzionální matice  $\underline{\mathbf{M}}$  je tak složena ze třech řádků, třech sloupců a třech vlnových délek  $\underline{\mathbf{M}}(i,j,k)=\underline{\mathbf{M}}(3,3,3)$ . Vícedimenzionální data pak mohou být (a v drtivé většině případů jsou) vystavena velkému počtu operací předzpracování. Jde především o ořez dat (ořez v prostorové rovině, nebo odstranění specifických vlnových délek). Dále mezi základní operace patří zvýšení jasu a kontrastu, váhování a průměrování. Analýza hyperspektrálních dat však není předmětem této práce, budeme proto uvažovat pouze ty metody, která nám jsou schopné přinést určitý přínos pro účely komprese a úspory dat.

### 3.6.1 Body zájmu

Všechny metody zobrazování pro různá odvětví vytvářejí regiony většího nebo menšího bodu zájmu pro zkoumajícího. Region, který má pro další analýzu určitý význam, se značí jako oblast zájmu ROI (viz Obrázek 3.9). Pixely, které nemají žádný, nebo zanedbatelný význam, jsou nazývány pixely pozadí. Mnoho metod analýzy obrazu uvažuje všechny dostupné pixely a předpokládají, že celý obraz dává smysl vzhledem ke zkoumanému problému. Uvažují, že pixely pozadí nemají negativní vliv pro výpočty požadovaných analytických modelů atd. [7].

- Medicína – tomografie – obraz popisuje prostor (vzduch) mezi měřícím aparátem a zkoumaným subjektem (tělo pacienta). Některé zobrazované orgány mohou být zobrazeny velmi kvalitně, přestože nejsou primární oblastí zájmu zkoumání.
- Satelitní zobrazování – například vodní plochy (jezera, moře, rybníky) mohou být nedůležité pro mapování terénu, a naopak terén může být nedůležitý při zkoumání vodních ploch. Celé regiony obrazu nebo specifická pásma vlnové délky mohou být také zkreslena množstvím satelitních chyb. To vyžaduje korekci nebo odstranění těchto hodnot, pokud není možné uplatnit vhodnou korekci.
- Ve všech mikroskopických metodách je zkoumaný subjekt umístěn do určitého média. V optické mikroskopii je tímto médiem tekutina nebo transparentní polymer [7]. Toto médium není primárním zájmem a pixely jej reprezentující mohou být pro většinu aplikací ignorovány.

Někdy je nutné získat dílčí vzorek obrazu. Důvody pro tuto operaci se mohou různit. Obvykle souvisí s definicí problému. Nebo může jít o možnost, jak uživateli poskytnout mnohem menší náhled dat. První jednoduchou metodu je liniové nebo sloupcové přeskakování. Přeskakováním označujeme situaci, kdy používáme pouze každý druhý, třetí, čtvrtý (atd.) řádek nebo sloupec – jde tedy o operaci analogickou k decimaci vzorkovací frekvence. Dále může být použito liniové i sloupcové přeskakování zároveň. Touto technikou dochází k razantnímu poklesu rozlišení. Například použitím přeskakování sloupců i sloupců faktorem 4 dochází k celkové šestnáctinásobné redukci rozlišení [7]. Pro výpočet určitých statistických parametrů je tato redukce neškodná. V jiných případech, může vzorkování v pravidelných mřížkách vytvářet problémy, zejména, obsahuje-li obraz určité pravidelné struktury. Lokální selekce obrazové podmnožiny může být použita, pokud jsou určité části obrazu více důležité než jiné. Nativní a jednoduchou metodou je selekce obdélníkových podmnožin uvnitř oblasti zájmu. Tyto podmnožiny (subsets) byly dříve počítány zejména z důvodu usnadnění výpočtů pro tehdy pomalé počítače. V současnější literatuře se tato operace používá často pro definování více homogenních podmnožin. Například [31] pomocí obdélníkových podmnožin vícespektrálních obrazů definuje třídu vegetace, hor nebo pouště z šestikanálového leteckého snímáče.



**Obrázek 3.9 Multispektrální fotografie, červený čtverec představuje ROI.**

*Pozn. použitá fotografie je z příručky analýzy multispektrálních a hyperspektrálních dat [9].*

## 4. Kompresní metody

### 4.1 Základní rozdělení kompresních metod

Základní členění hyperspektrální komprese odpovídá členění klasických algoritmů komprese digitálních dat, rozlišují se podle ztrátovosti, tedy podle toho, jakou měrou odpovídají rekonstruovaná data datům původním. V případě, že jsme schopni z komprimovaných dat získat nezměněná původní data a nedochází k odstranění informace, hovoříme o bezeztrátové kompresi. K úspoře v tomto případě dochází vhodnějším způsobem uložení dat [5], kompresní algoritmy tohoto typu zpravidla obsahují blok prediktoru, následovaný entropickým kódem residuálů. Kompresní poměr, jehož tímto typem komprese můžeme dosáhnout, se blíží 3:1 [15]. To je však příliš málo pro použití na cílových zařízeních. Ideální použití bezeztrátové komprese je pro archivaci uložených dat koncovým uživatelem.

Ztrátová komprese naopak zanáší do dat určitou míru zkreslení a z komprimovaných dat tak již nemůžeme získat identické hodnoty, jaké jsme naměřili. Tyto metody obecně mají nastavitelné parametry, které ovlivňují křivku „rate-distortion“, tedy závislost kompresního poměru na míře zkreslení. Typ informace, která může být odstraněna, se odvíjí od dalšího využití dat [5]. Redukování datového toku zvyšuje zkreslení a naopak [15]. Zřejmě nejdůležitější oblastí využití ztrátové komprese dat je počáteční analýza rozsáhlých hyperspektrálních dat pro určení, které oblasti bude vhodné podrobit další analýze [5].

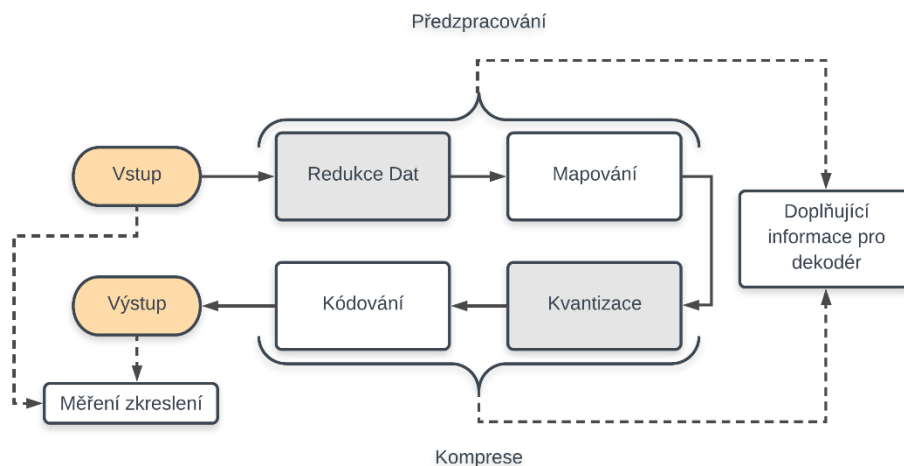
Pokud zkreslení zůstává velmi malé, může být algoritmus klasifikován jako téměř bezeztrátový. V literatuře [15] se v souvislosti s hyperspektrálními daty objevují dvě definice. První považuje kompresi za téměř bezeztrátovou, pokud distorze kompresí zůstane pod hladinou vlastního šumu senzoru, protože kvalita dat zůstává stejná. Druhá, méně používaná definice, uvažuje téměř bezeztrátovou kompresi v případě, že je zkreslení omezeno určitým intervalem.

## 4.2 Architektura kompresních metod pro hypersp. data

Velkým impulsem pro výzkum v oblasti hyperspektrální komprese dat byl start satelitu Hyperion v listopadu 2000 [32]. Demonstroval totiž jednak využitelnost těchto dat a zároveň nastínil trend zvyšování prostorového i spektrálního rozlišení, což má za následek dramatický nárůst objemu dat. Komprese hyperspektrálních dat musí překonávat řadu překážek – první je obrovský objem generovaných dat, druhou je jejich vědecké využití a třetí překážkou je povaha snímání [5]. Objem generovaných dat vyžaduje, aby komprese byla co nejúčinnější, vědecké využití zároveň vyžaduje, aby rekonstruovaná data byla co možná nejvěrnější datům zdrojovým a povahou snímání je myšlena skutečnost, že data bývají často snímána například na oběžné dráze a je potřeba aplikovat kompresi ihned po nasnímání, ta tím pádem nesmí být výpočetně náročná a doba zpracování musí být co možná nejrychlejší. Elektronika satelitu je totiž vystavena atypickým podmínkám – musí být odstíněná před okolní radiací a zároveň být kvalitně chlazená, aby byla teplota senzoru pokud možno konstantní a nebyl do snímaných dat zanesen příliš vysoký šum. Je zřejmé, že není možné dodržet všechny tyto podmínky současně. Kompromisu mezi těmito podmínkami se věnuje literatura [15].

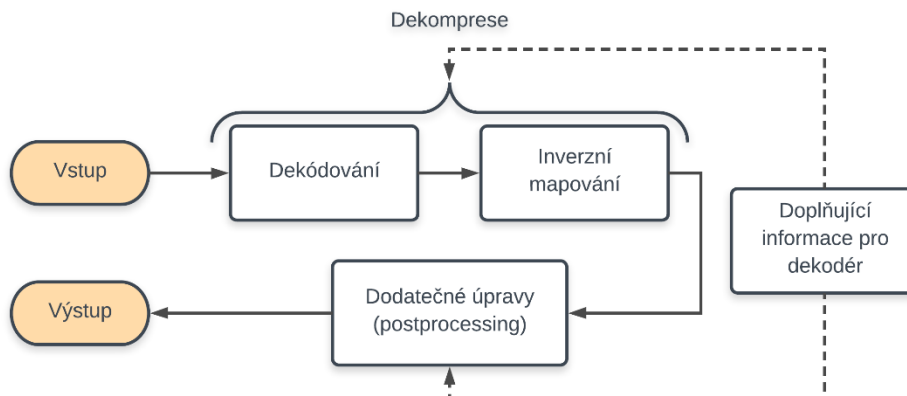
Hyperspektrální data tak přináší pozoruhodné výzvy, týkající se neobvyklého vztahu mezi obsaženou spektrální a prostorovou informací. Spektrální dimenze obvykle obsahuje vysokou míru korelace, jež by měl kompresní algoritmus využít [15]. Po prostudování velkého množství literatury (např. [7],[8],[15],[33],[34],[35]), týkající se hyperspektrální komprese a její aplikace na reálná data, bylo dosaženo zjištění, že se opakuje několik velice podobných přístupů, které by se daly rozdělit do tří základních skupin. První skupina se snaží využít známé poznatky 2D komprese obrazových dat, které s mírnými úpravami aplikují na jednotlivé řezy hyperkrychle (využívá například [35] a [33]). Kladem je vysoká rychlost a jednoduchost, nevýhodou je ignorování vysoké korelace dat ve spektrální dimenzi, což má za následek nižší kompresní poměry. Druhá skupina algoritmů se snaží této podobnosti využít na začátku řetězce, dochází k dekorelaci pouze spektrální dimenze a následně jsou opět použity principy 2D komprese. Tento přístup již dosahuje vyšších kompresních poměrů, zároveň je však pomalejší a složitější na realizaci. Třetím přístupem je návrh 3D kompresních algoritmů, které data dekorelují a následně kvantizují pro všechny tři dimenze současně (v praxi ověřuje [34], snaží se přitom o srovnání s prvními dvěma skupinami 1D a 2D dekorelace). Tento přístup by tak měl dosahovat největších kompresních poměrů, avšak za cenu mnohem vyšší výpočetní náročnosti a doby výpočtu. Všechny tři zmíněné případy mohou být aplikovány ztrátově, bezztrátově i téměř bezztrátově. Na úplný konec těchto algoritmů bývá zařazen určitý typ redundančního kódování, nejpoužívanější je RLC a Huffmanovo kódování. Kompletní přehled hyperspektrálních kompresních algoritmů poskytuje [5].

Velmi detailní příručka návrhu kompresních řetězců hyperspektrálních dat poskytuje [15], podle něhož musí být prvním krokem určení, na kterém místě přenosového řetězce budou data vystavena kompresi. Tím dojde k definování parametrů dat, se kterými budeme pracovat a omezení, která bude nutné překonat. Řetězec získávání je pak podobný pro oba možné případy – pro senzor ve vzduchu i pro senzor ve vesmíru. Komprese většinou probíhá na několika separátních vrstvách řetězce – s rozdílnými nároky a překážkami. Prvním místem, kde se s kompresí můžeme setkat, je samotný proces akvizice. Tento jev je označován jako komprimované snímání [15]. Dále řadí kompresní metody to třech základních skupin – predikce, vektorová kvantizace a transformační kódování.



**Obrázek 4.1** Kompletní blokové schéma kodéru hyperspektrálních dat.

*Při návrhu bylo vycházeno z informací dostupných v [8], doplněných o poznatky z [5].*



**Obrázek 4.2** Kompletní blokové schéma dekodéru hyperspektrálních dat.

*Při návrhu bylo vycházeno z informací dostupných v [8], doplněných o poznatky z [5].*

Základní architektura kodéru (viz Obrázek 4.1) se skládá z následujících komponent – předzpracování a komprese. Část předzpracování obvykle zahrnuje aplikování určitých jednoduchých, avšak nezvratných procesů. Ty mohou být jednoduše externě poskytnuty přímo dekodéru, pro dosažení lepší efektivity. Mezi tyto operace předzpracování patří například normalizace, PCA analýza, shlukování (pre-clustering) a přeřazení dat [5]. Následná kompresní část zahrnuje použití některé ze standardizovaných technik, například vektorové kvantizace, nebo některé z transformačních technik, upravených pro použití na hyperspektrálních datech. Dekodér (viz Obrázek 4.2) se skládá z dekódovací části a dodatečných úprav (post-processingu). Rekonstrukce a post-procesingové části jednoduše provádí inverzní operace k těm, které byly provedeny ve fázi pre-procesingu a komprese.

### 4.3 Trendy a směr vývoje hyperspektrální komprese

Vývoj kompresních algoritmů i nadále řeší kompromis nastíněný v kapitole 4.2, tedy snaží se dosáhnout co možná nejnižší doby komprese a zkreslení při současném dosažení dobrých kompresních poměrů. Mnoho kompresních metod hyperspektrálních dat je již úspěšně zavedeno v provozu v reálných podmínkách. Příkladem může být podle [15] klasifikační systém, který byl navržen pro satelit Nemo. Tento systém, pojmenovaný Optical Real-time Adaptive Signature Identification System (ORASIS), je schopen kompresních poměrů 30:1, přičemž poskytuje dobrou kvalitu pro klasifikační aplikace. Příklad transformační aplikace uvádí opět [15], modifikovanou verzi SPIHT je vybavena sonda, která má za cíl zkoumat kometu 67P/Churyumov-Gerasimenko. Tato modifikovaná verze SPIHT byla navržena pro komprimování hyperspektrálních dat VIRTIS. Vektorová kvantizace je v současné době vývoje již velmi pokročilá, použitelnost byla demonstrována implementací FPGA [5]. Tento algoritmus byl navíc vřele přijat komunitou uživatelů, zabývajících se hyperspektrálními daty. Byly demonstrovány aplikace, jež dosahovaly kompresních poměrů až 30:1, přičemž data byla použitelná pro většinu aplikací.

Jako jeden ze současných trendů kompresních algoritmů hyperspektrálních dat uvádí [15] snahu získat to nejlepší z obou směrů – ze ztrátové i bezztrátové komprese. Cílem je progresivní datový tok, který bude schopen dosáhnout bezztrátové kvality. Existuje několik způsobů, jak dosáhnout zmíněného – například použít bezztrátový algoritmus, který je schopen pracovat v progresivním režimu, nebo použít hybridní řešení, kombinující ztrátový algoritmus, aplikující techniky chybové kódování. V prvním zmíněném případě může být použito kódování JPEG 2000, aplikující 5/3 vlnkovou transformaci [5]. Datový tok je progresivní – kódování pouze začátku komprimovaných dat produkuje data o nižší kvalitě, může však dojít k adaptování pro různé specifické aplikace.

Pokud je kódován celý datový tok, je možné data obnovit bez jakéhokoliv zkreslení. Jedním z hlavních záporů této metody je relativně nízká kvalita, kterou získáme pro náročnější datové toky – použitá vlnková transformace totiž není tak efektivní jako 9/7 pro dekorrelaci hyperspektrálních dat. Druhé řešení kóduje zbytkovou chybu ztrátového kódování. Tato reziduální chyba může být kódována například pomocí DPCM schématu [15]. Efektivnost ztrátové komprese je zachována a zbytková chyba je použita pouze pokud je to požadováno uživatelem, to však zvyšuje komplexitu algoritmu, hlavně z hlediska nároků na paměť. Tyto metody nacházejí uplatnění hlavně v segmentu pozemního zpracování pro archivaci dat, kde jsou požadavky na nízkou komplexitu uvolněnější a kde nejsou tolerovány ztráty transkódováním.

#### 4.4 Metody transformace

Transformační kódování probíhá ve dvou krocích. Prvním je podle [15] transformace dat do domény, ve které je reprezentace dat více kompaktní z hlediska energie a lépe korelovatelná – dochází k násobení hodnot původních vzorků souborem básových vektorů (typicky vzorkované harmonické funkce s narůstající frekvencí) pro dosažení hodnot produktů; ty jsou následně sčítány, tím jsou získány výsledné koeficienty, indikující frekvenční obsah původního vlnového průběhu. [5] zmiňuje dva různé případy, které mohou nastat – pokud budou hodnoty původních vzorků tvarem zhruba odpovídat básovým vektorům, pak budou hodnoty produktů převážně kladné a hodnota jejich součtu bude vysoká; pokud odpovídat nebudou, suma hodnot produktů bude blízká nule. V případě, že mají mezi sebou sousední vzorky původních dat velkou míru korelace, pak velké množství koeficientů vyšších frekvencí bude blízkých nule a koeficienty samotné mohou být uloženy nebo odeslány menším počtem bitů, než byla původní data. Druhým krokem je kódování této informace tak efektivně, jak je jen možné. Právě ve druhém kroku dochází ke ztrátě informace a snížení velikosti dat, typicky určitou formou kvantizace.

Krok transformace využívá korelace mezi spektrálními kanály (1D), korelace v prostorové doméně (2D), případně kombinaci obojího (3D). Zdroj [15] poukazuje na mnohem pomalejší variace ve spektrální doméně, než je tomu v prostorové doméně, naznačuje tedy lepší vhodnost 1D přístupu než 2D přístupu. Pokud bychom toto tvrzení trochu přeformulovali, v praxi by znamenalo, že hyperspektrální snímek určité velikosti by měl být mnohem lépe komprimovatelný, než jednorozměrný snímek stejné velikosti (s mnohem vyšším rozlišením prostorové dimenze). Hlavním negativem transformačních metod je výpočetní náročnost. Básově vektory závisí na vstupních datech, což například pro satelitní snímání příliš vhodné, například KLT by byla v tom případě implementovatelná pro maximálně 200 spektrálních pásem.



Došlo k určitým návrhům, jak toto omezení překonat, například předzpracování transformačních koeficientů typických obrazových dat a znovu užití těchto koeficientů pro všechna obrazová data [15]. To bohužel funguje pouze pro multispektrální obrazy s několika kanály, nikoliv pro hyperspektrální obrazy, protože variace ve spektru mezi pixely se stává příliš důležitá na to, aby mohla být efektivně dekorelována průměrnou KLT. Další populární transformační metodou je vlnková transformace. Jakmile je energie zkompatněna malým množstvím koeficientů, dochází k efektivnějšímu přeřazení hodnot (první ty s vyšším významem) a následně může být použito několik metod pro kódování těchto hodnot. Zmíněné vlastnosti využívají algoritmy zerotree, například EZV, SPIHT a SPECK. Jakmile je navržen způsob přístupu k datům, probíhá samotné kódování za využití minimálního množství symbolů. Nejčastěji se využívá aritmetických kodérů, jejichž implementace je ovšem složitá, proto se dále používají například kodéry RLC, LZW, nebo Huffmanovo kódování. Většina ze současně používaných algoritmů využívá kombinace těchto odlišných kroků, například JPEG 2000 kombinuje vlnkovou transformaci s kontextuálním aritmetickým kodérem. 3D-SPIHT kombinuje vlnkovou transformaci se stromovým řazením [15].

V bloku dekodéru je každý bázový vektor násoben korespondujícím koeficientem a výsledné škálované bázové vektory jsou přičteny dohromady, což produkuje původní vzorky [5]. Mnohdy stačí pouze malé množství koeficientů nízkých frekvencí k produkování kvalitní reprodukce původních dat. Aby byl transformační proces dokonale reversibilní, musí být bázové vektory ortonormální.

#### 4.4.1 PCA

Principem PCA je redukce dimenzionality vstupních dat na základě jejich ortogonální transformace do souřadnicového prostoru o nižší dimenzionalitě [8]. Předpokládá totiž fakt, že ačkoliv vstupní data obsahují až několik stovek spektrálních kanálů, pro popis těchto dat jich mnohdy stačí jen několik [10]. PCA tedy hledá prostor, který nejlépe reprezentuje směr maximální odchylky dat, největší uplatnění nalézá při těžbě dat, strojovém učení, extrakci informace, chemii a zobrazování vícerozměrových obrazových dat [36]. Transformace samotná má dva rozdílné přístupy – transformace s učitelem a bez učitele. Při transformaci s učitelem dochází k definování tříd, jež jsou použity při hledání transformačního prostoru. Přístup bez učitele hledá prostor o nižší dimenzionalitě bez definování tříd a více se využívá právě pro účely vizualizace. Existuje několik různých definic a způsobů výpočtů, pro účely zpracování obrazových dat se však zpravidla využívá výpočtu pomocí kovarianční matice [35].

Jak již bylo zmíněno, cílem PCA je nalézt prostor nižší dimenzionality, do nějž jsou transformována vstupní data (viz Rovnice 4.1). Směr PCA prostoru reprezentuje směr maxima odchylky těchto dat, dochází k transformaci do PCA prostoru  $R^k$ . Ten se sestává z  $k$  hlavních (princiálních) komponent, které jsou nekorelovatelné a ortonormální. První hlavní komponenta  $PC_1$  reprezentuje směr největší odchylky dat, druhá hlavní komponenta  $PC_2$  směr druhé největší odchylky atd. [5]. Jako další využití PCA pro analýzu obrazu uvádí [8] shlukování pixelů do tzv. clusterů, tedy skupin pixelů podobných vlastností. Tyto clustery mohou být dále ohraničeny polygonem, takovýmto rozčleněním pixelů může docházet ke značné redukci dat, například selekcí neužitečného pozadí a subjektu zájmu. Další obrovskou výhodou analýzy PCA je podle [7] možnost geometrické reprezentace vícerozměrných dat pro jejich rychlejší a jednodušší posouzení. Jednoduchou projekcí vícerozměrných dat do variabilního prostoru lze okamžitě nalézt proměnné, jež mají největší vliv na podobu dat.

$$X = \{x_1, x_2, x_3, \dots, x_N\}; X \in R^M \quad 4.1$$

**Rovnice 4.1 Vstupní data PCA.**

*N je celkový počet vzorků, každý vzorek je definován M proměnnými.*

Prvním krokem PCA pro účely komprese je podle [37] definování matice průměrů – ta obsahuje průměrné hodnoty pro každý řádek obrazu (pro každou vlnovou délku v případě hyperspektrálních dat). Jde tedy o matici, jež má shodné sloupce. Tato matice průměrů je následně odečtena od vstupních dat (krok centrování). Následně se vypočítá kovarianční matice těchto dat (viz Rovnice 4.2). Dalším krokem je vypočítání vlastních čísel a vlastních vektorů kovarianční matice. Ty jsou následně seřazeny sestupně na základě jejich velikosti. V následujícím kroku je definována výsledná míra komprese – dochází totiž k redukci vlastních vektorů. Těch je použito pouze  $k$  s nejvyšší hodnotou. V případě použití všech vypočítaných vektorů a vyhnutí se zaokrouhlování v průběhu dílčích výpočtů je transformace bezeztrátová [7]. Na konci kódovacího procesu jsou vybrané vektory vynásobeny průměrovou maticí (viz Rovnice 4.3). Vlastní čísla jsou skaláry a odpovídají škálovacímu faktoru – délce, magnitudě a robustnosti vlastních vektorů, ty jsou vždy nenulové a reprezentují hlavní komponenty (každý vektor reprezentuje jeden hlavní komponent). Inverzní proces je popsán (viz Rovnice 4.4).

$$\sum = \frac{1}{N-1} D \times D^T \quad 4.2$$

**Rovnice 4.2 Výpočet kovarianční matice.**

*N je celkový počet vzorků vstupních dat X, D je matice centrováných dat.*

$$Y = W^T D = \sum_{i=1}^N W^T (x_i - \mu) \quad 4.3$$

**Rovnice 4.3 Proces PCA.**

*Y je projekce dat do nižší dimenzionality; W je prostor PCA; D je centrovací matice; N je celkový počet vzorků vstupních dat X;  $x_i$  je i-tý vzorek;  $\mu$  je průměr aktuálně analyzovaného řádku.*

$$\hat{X} = WY + \mu = \sum_{i=1}^N W y_i + \mu \quad 4.4$$

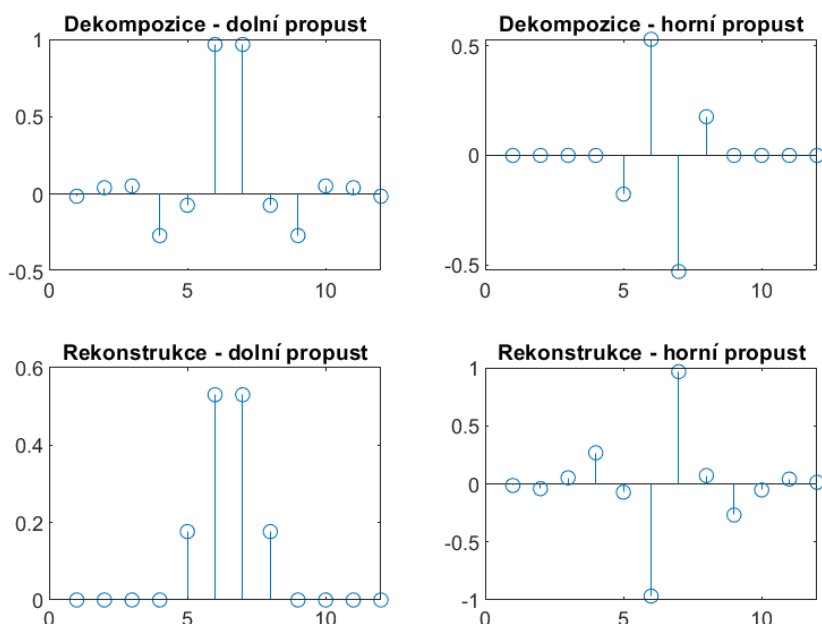
**Rovnice 4.4 Inverzní PCA.**

*$\hat{X}$  jsou rekonstruovaná data, Y je projekce dat do nižší dimenzionality; W je prostor PCA; D je centrovací matice; N je celkový počet vzorků vstupních dat X;  $y_i$  je i-tý vlastní vektor;  $\mu$  je průměr aktuálně analyzovaného řádku.*

#### 4.4.2 Wavelet

Vlnková transformace (neboli wavelet transform) využívá vlastnost reálných dat, jež se obvykle skládají z pomalu se měnících trendů (oscilací), přerušovanými rychlými změnami, tzv. transienty. Na podobnou vlastnost obrazových dat upozorňuje [38], ta obsahují podobné oblasti, ohraničené ostrými hranami nebo náhlými změnami kontrastu. Tyto náhlé změny bývají často nejzajímavější částí dat jak z hlediska vnímání, tak poskytnuté informace. Často používaná Fourierova transformace je silným nástrojem, skýtá však jeden zásadní nedostatek – náhlé změny nereprezentuje příliš efektivně. Důvodem je princip Fourierovy transformace – reprezentuje data jako sumu harmonických funkcí, které nejsou lokalizovány ani v čase, ani v prostoru ~ jsou nekauzální [38]. Proto musí být pro přesnější analyzování signálu s rychlými změnami definována nová třída funkcí, které jsou dobře lokalizované v časové i frekvenční oblasti. Tyto vlastnosti splňují například tzv. vlnky (waveletové funkce). Vlnka je finitní signál, jde o rychle tlumenou vlnovou oscilaci o nulovém výkonu (viz Obrázek 4.3). Vlnky samotné mají rozdílné tvary a velikosti, jejich volba se liší v závislosti na potřebné aplikaci.

### Čtyři použité filtry pro vlnku typu – Biortogonál 3.5



Obrázek 4.3 4 Filtry použité pro DWT typu Biorthogonal 3.5 v programu MATLAB.

K vlnkám se vztahují dva velmi důležité koncepty – škálování a posuv [38]. Škálování je proces smršťování nebo roztahování vlnky v časové oblasti (viz Rovnice 4.5). Škálování je definováno faktorem, jímž je vlnka smrštěna/roztahena. Tento faktor je pevně spjat s frekvenční oblastí. Například škálování faktorem 2 vede ke snížení frekvence signálu na polovinu (tedy o oktávu). Tento koncept proporcionality je nazýván termínem středová frekvence vlnky (viz Rovnice 4.6). [38] upozorňuje, že na rozdíl od nekauzálního sinusového signálu má vlnka pásmovou frekvenční charakteristiku. Roztažená vlnka je vhodnější pro popis ustálenějšího stavu signálu (malé frekvence), smrštěná vlnka se více hodí pro náhlé transienty. Posuvem vlnky je myšleno zpoždování (kladné i záporné) v časové oblasti (viz Rovnice 4.7) v rámci vzorkovaného signálu. Dvě nejpoužívanější transformace v oblasti vlnkové analýzy jsou CTW (Continuous Wavelet Transform) a DWT (Discrete Wavelet Transform).

$$\Psi\left(\frac{t}{s}\right) s > 0 \quad (4.5)$$

**Rovnice 4.5 Škálování vlnky.**

*s je faktor škálování,  $\Psi(t)$  je vlnka v časové oblasti*

$$F_{eq} = \frac{C_f}{s\delta t} \quad (4.6)$$

**Rovnice 4.6 Vztah šk. faktoru k časové a frekvenční oblasti.**


*C<sub>f</sub> je středová frekvence, s je faktor škálování a  $\delta t$  je vzorkovací interval*

CWT je klíčová pro tyto aplikace – časovo-frekvenční analýza, filtrování časově lokalizovaných komponent. Pro časově-frekvenční analýzu, neboli scalogram/spektrogram, se nejvíce hodí analytické modely vlnek bez komponent negativní frekvence, mezi než patří například vlnky Morse, Bump a Analytic Morlet. Mezi klady CWT patří větší flexibilita díky možnosti dodatečného škálování (intermediary scaling) pro každou oktávu, což umožňuje jemnější škálovací analýzu [38]. Tento parametr se označuje jako škálování na oktávu (scales per octave). Čím větší hodnota, tím jemnější diskretizace – lepší popis oscilace signálů. Pro kompresi obrazových dat se CWT nevyužívá.

$$\phi(t - k) \tag{4.7}$$

**Rovnice 4.7 Časový posuv vlnky.**

*Kde k odpovídá časovému posuvu.*




**Obrázek 4.4 2D DWT – způsob transformace obrazu pro jednotlivé úrovně dekompozice.**

*a) 2D DWT 1. úrovně b) 2D DWT 2. úrovně c) 2D DWT 3. úrovně*

DWT lze označit za subpásmovou filtrační operaci [5]. Vstupní signál je filtrován tak, že produkuje dvě verze sama sebe – jednu po průchodu dolní a jednu horní propustí dekompozičních filtrů a následně jsou podvzorkovány (decimovány) faktorem 2. Dochází tak k separaci aproximačních a detailových koeficientů [38]. Nejvíce se hodí pro odstraňování šumu a kompresi signálů, včetně obrazových dat. Pomáhá totiž popsat mnoho přirozeně probíhajících jevů menším počtem koeficientů, čímž umožňuje řidší interpretaci. Základní škálování je nastaveno jako číslo  $2^j$ , přičemž  $j$  je celočíselný exponent ( $j=1,2,3,4,\dots$ ). Translace probíhá pomocí celočíselných násobků  $2^j \cdot m$  ( $m=1,2,3,4,\dots$ ) [38]. Tento způsob vzorkování eliminuje redundanci koeficientů. Výstup transformace vytváří stejný počet koeficientů jako je délka vstupního signálu. Proces DWT je ekvivalentní k porovnávání signálu k diskretnímu bankám filtrů, postupně rozděluje signál na subpásma nižší frekvence – transformaci lze provést několikrát a dosáhnout tak vyšší úrovně (viz Obrázek 4.5).

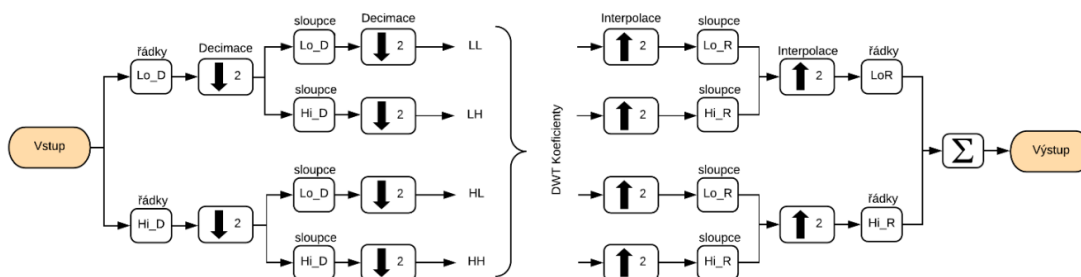
Délka koeficientů v rozděleném pásmu je vždy poloviční vzhledem k délce v předchozím kroku. Pomocí této techniky lze zaznamenat zkoumaný signál za pomoci několika DWT koeficientů o velké magnitudě, přičemž šum v signálu zůstává zachován v malých koeficientech. Tímto DWT napomáhá analyzovat signály v progresivně užších subpásmech.

2D DWT je velmi známá z oblasti komprese klasických obrazových dat (viz Obrázek 4.4), rozdíl mezi principem 1D a 2D DWT lze nejlépe pochopit po porovnání schém (viz Obrázek 4.5 a Obrázek 4.6). Přechod na 3D DWT je analogický, je možné separovat ho na dílčí 1D DWT transformace – první v rámci spektrální dimenze, druhá v rámci řádků a třetí v rámci sloupců.



Obrázek 4.5 Blokové schéma 1D DWT a IDWT 2. řádu.

Pro produkci rekonstrukce dat jsou subpásmové vzorky nejdříve nadvzorkovány (interpolovány – mezi liché vzorky je vložena nula) faktorem dva a poté filtrovány tak, aby došlo k opětovnému rekonstruování nefiltrovaných verzí signálu (dolní a horní propusti rekonstrukčními filtry). Dvoukanálový dekompoziční proces může být opakován ve verzích filtrovaných dolní propustí pro získání dekompozice ve víceúrovňovém rozlišení.



Obrázek 4.6 Blokové schéma 2D DWT a IDWT 1. řádu.

DWT tedy patří mezi velmi variabilní metody transformace. Lze jej aplikovat ve více dimenzích a pomocí kaskádovitě opakování (Obrázek 4.5) ve formě banky filtrů i ve více úrovních. Například [33] využívá 1D DWT jako spektrální dekorelátor, jehož výstup komprimuje JPEG-LS, [34] 1D KLT algoritmus jako spektrální dekorelátor a 2D DWT jako prostorový dekorelátor. Dále se tématem zabývá [33], testuje specifické nastavení kompresního poměru vzhledem ke komplexitě výpočtu a výsledného kompresního výkonu na datech AVIRIS.

### 4.4.3 KLT

KLT (Karhunen-Loeve Transform) je podle [5] teoreticky nejefektivnější transformací pro maximalizování množství energie obsažené v malém množství koeficientů, vycházející z PCA. Bázové vektory KLT jsou generovány pro každou konkrétní množinu dat z kovarianční matice dat (viz Rovnice 4.8), zároveň odpovídají vlastním vektorům kovarianční matice a proto platí (Rovnice 4.9).

$$r_{i,j} = \sum_{k=1}^N (x_{i,k} - \bar{x})(x_{j,k} - \bar{x}) \quad \text{pro } i, j = 1 \dots B \quad (4.8)$$

**Rovnice 4.8** Kovarianční matice  $r_{ij}$ .

*index  $k$  označuje  $k$ -tou hodnotu v pásmu  $i$ ,  $N$  je počet pixelů v každém pásmovém snímku a  $B$  je počet spektrálních pásem.*

$$RT = TD \quad (4.9)$$

**Rovnice 4.9** Vztak kovarianční matice a diagonální matice vlastních čísel.

*$R$  je kovarianční matice,  $D$  je diagonální maticí vlastních čísel  $R$ .*

Jedním ze způsobů, jak vizualizovat proces transformace, je nahlížet na něj jako osy rotace v  $B$  dimenziálním prostoru, kde  $B$  je délka bázových vektorů [5]. Po nalezení koeficientů KLT můžeme tyto koeficienty označit za nový souřadnicový systém, který vykazuje výrazně vyšší odchylku podél jedné osy než druhé (popř. dalších při větším počtu dimenzí). Vlastnosti KLT ji přímo nabízí k použití pro kompresi dat, protože koeficienty, které vykazují nejmenší vliv na odchylku dat, mohou být zahozeny a výsledná chyba v dekodéru bude minimální. Pokud bychom například přenášeli pouze  $c_1$ , datový tok bude poloviční a výsledná chyba mezi komprimovanými a původními daty bude minimální možná chyba pro daný počet koeficientů.

Proces KLT transformace je velmi podobný PCA analýze, která se používá pro redukcí dimenzionality dat [7]. Pokud vícedimenzionální data v původním datovém prostoru obsahují vysokou míru korelace, PCA umožňuje reprezentovat tato data pomocí pouhé jedné dimenze v transformovaném systému souřadnic [5]. Nevýhodou KLT procesu je to, že je velmi závislý na použitých datech a optimální bázové vektory musí být přepočítány a odeslány jako příloha komprimovaných dat. [15] dále zmiňuje nutnost úpravy algoritmu pro použití na data obsahující více než 200 frekvenčních pásem – natrénovat algoritmus na typickém souboru dat a část koeficientů využít jako vzor pro další výpočty. Tento problém může být překonán pomocí použití pevné množiny bázových vektorů, které jsou známé jak kodéru, tak dekodéru; tento způsob využívá například i diskrétní kosinová transformace (DCT).

Využití KLT pro kompresi hyperspektrálních dat popisuje například [39] pro využití v oblasti satelitního snímání. Další možnosti využití jsou popsány [40], upozorňuje však na problém související s vyšší výpočetní náročností procesu.

#### 4.4.1 DCT

DCT (Discrete Cosine Transform) je suboptimální transformace, která se používá v obrazové a video kompresi běžných obrazových dat. Vztah pro výpočet bázových vektorů DCT je (Rovnice 4.10) [5]. Proces je velmi podobný transformaci KLT (kapitola 4.4.3).

V oblasti komprese hyperspektrálních dat nepatří DCT k nejpoužívanějším metodám. Existují však články, které dokazující možnost aplikace dokazují. Například [41] úspěšně aplikoval M-NVQ (Mean-normalized Vector Quantization) v prostorové dimenzi a DCT (Discrete Cosine Transform) ve spektrální dimenzi a dosáhl až 2,5 krát lepších výsledků než při použití samotné M-NVQ v obou dimenzích.

$$t_{m,u} = k_u \sqrt{\frac{2}{N}} \cos\left(\frac{(2m+1)u\pi}{2N}\right) \quad \text{pro } m, u = 0, 1, \dots, B-1$$

*kde  $t_{m,u}$  je  $m$ -tý element  $u$ -tého bázového vektoru  $a$*

$$k_u = \begin{cases} 1 & u = 0 \\ \sqrt{2} & u = 0 \\ 1 & \text{jinak} \end{cases} \quad (4.10)$$

**Rovnice 4.10** Matematický popis získání bázových vektorů DCT.

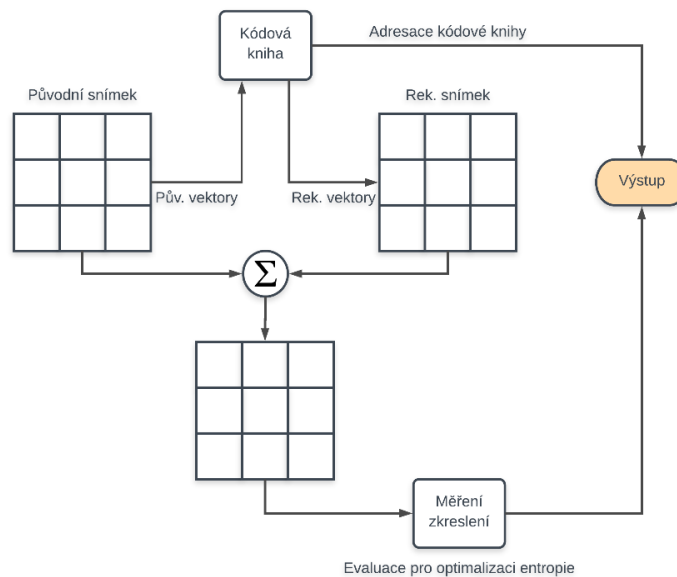
Průběh typické DCT v prostorové dimenzi shrnuje [42] v několika krocích. Obraz je segmentován (typicky 8x8); hodnoty jsou normovány tak, aby alternovaly kolem nuly (pro 8bitovou hloubku je od každého pixelu odečtena hodnota 128); následně je prováděn výpočet samotných DCT koeficientů, ty se váží tak, aby hodnota v levém horním rohu segmentu byla mnohem vyšší než ostatní (DC koeficient); v případě ztrátové komprese dále probíhá zaokrouhlování. Výsledek je obvykle řazen zig-zag řazením, čímž je dosaženo dlouhých řetězců nul, data jsou tedy připravená pro některý typ kódování, například Huffmanovo nebo aritmetické.



## 4.5 Metody kvantizace

### 4.5.1 Vektorová kvantizace

Použití vektorové kvantizace (zkráceně VQ) se přímo nabízí z povahy hyperspektrálních dat, protože jejich nejčastěji používanou aplikací je klasifikace dat [15]. Pokud klasifikační algoritmus uvažuje pouze diskrétní pixely jeden po druhém, je každý pixel přiřazen nejbližší třídě (uvažujeme vzdálenost klasifikace). To s sebou přirozeně nese pojem kódové knihy, každé slovo představující jeden z nasnímaných materiálů. Pro přenos informace je pak nutná pouze kódová kniha (třídy) a mapa (klasifikace), což vede ke značnému snížení velikosti dat.



Obrázek 4.7 Blokové schéma VQ pro účely komprese obrazových dat.

*Při návrhu bylo vycházeno z [5].*

Kvantizace samotná se dá podle [15] rozdělit do tří hlavních kroků – formování vektoru, generování tréninkového setu, generování kódové knihy a kvantizace. Prvním krokem je dekompozice obrazové informace do množiny vektorů [5], následně je vytvořena podmnožina vstupních vektorů (trénovací soubor), pomocí nichž je vygenerována kódová kniha (například pomocí GLA, neboli Generalized Lloyd Algoritmus [15]) a kódovací krok, obvykle za použití iterativního shlukování; na závěr dochází k nalezení kódového slova pro každý kódový vektor v kódové knize a dochází k odeslání tohoto slova. Proces VQ komprese může být alternován pomocí změny počtu a délky vektorů kódové knihy a přesnosti odesílaných rozdílových vektorů [5]. Popsaný postup bohužel vyžaduje poměrně velký výpočetní výkon a není pro zpracování hyperspektrálních dat příliš vhodný. Většina práce, věnované využití vektorové kvantizace, je soustředěna na zjednodušování tohoto kroku pro uvolnění podmínek komplexity [15]. Obecně lze říci, že se vektorová kvantizace pro kompresi hyperspektrálních dat využívá jen v případě, že je vyžadován malý kompresní poměr.

## 4.6 Metody predikce

Metody predikce přímo navazující na trendy bezztrátové komprese běžných 2D obrazových dat, spoléhající na korelaci mezi hodnotami sousedních pixelů, dochází k aplikaci predikčního kódování i na poli komprese hyperspektrálních snímků [15]. Predikční kódování nejprve aplikuje prediktor pro dekorelování vstupních dat. V druhém kroku je entropickým kóděrem kódována chyba predikce – kódovány jsou rozdíly mezi přesnou hodnotou daného pixelu a predikovanou hodnotou [43]. Typicky prediktor využívá pro predikci lineární funkce, odhadovaná hodnota se odvíjí od dříve zpracovaných pixelů [44]. Složitější prediktory jsou pak schopné využívat i silné korelace mezi sousedními frekvenčními pásmy, avšak většina z nich uvažuje pouze přímo sousedící pásma – což může podle [15] způsobovat problémy na přechodech určitých spektrálních regionů, například infračerveného a blízko-infračerveného – kde jsou patrné silné výkyvy z důvodu silné odezvy chlorofylu. Jako nejslibnější se v doméně predikčního kódování jeví použití vyhledávacích tabulek LUT a adaptace CALIC [5].

Protože vztah mezi různými frekvenčními pásmy vícedimenzionálního obrazu není předem znám, je vhodné najít dobrou funkci predikce pomocí předchozí analýzy obrazových dat, například metodou nejmenších čtverců. Článek [43] připomíná, že pro predikci aktuálně kódovaného pixelu můžeme použít pouze ty pixely, které byly zpracovány dříve (nikoliv ty, které čekají na zpracování). Tato podmínka platí pro prostorovou i spektrální dimenzi. Demonstruje, že může dojít k případu, kdy například pásmo 2 může být vhodným prediktorem pro pásmo 1 a jejich přeřazením lze dosáhnout vhodnější mezipásmové korelace. Následkem toho při použití DPCM kódování a dalšího přeřazení dat lze dosáhnout menších predikčních reziduálů. Jedinou cenou za zahrnutí tohoto procesu přeřazování je nutnost přiložit k datům přeřazovací mapu, jakožto doplňkovou informaci pro dekodér. Je ovšem nutné mít na paměti, že přestože můžeme nalézt konkrétní optimální řazení, nemusí být vždy praktické ho použít – typicky pro případ, kdy je nutné se zpětně odkazovat na určitá nekomprimovaná data. Pro data hyperspektrální se obvykle volí postup, kdy se pásma rozřadí do jistých podmnožin, přičemž každá z nich obsahuje stejné množství pásem. Tyto jednotlivé bloky jsou komprimovány společně při dodržení optimálního řazení [43].

#### 4.6.1 DPCM

Literatura [5] uvádí DPCM (Differential Pulse Code Modulation) jako techniku, která byla pro kompresi hyperspektrálních dat využita jako jedna z prvních. Termín pulzně kódované modulace (PCM) označuje proces vzorkování analogového vlnového průběhu do digitální binární sekvence. Diferenciální PCM je specializace zmíněného procesu, kdy jsou přenášeny pouze rozdíly mezi navazujícími vzorky (reziduály), namísto hodnot původních dat [5]. Patří tedy do skupiny prediktivního kódování. Predikce samotná je typicky datová hodnota, která zaujímá sousední polohu (ve spektrální, prostorové nebo dočasné dimenzi). Tyto hodnoty jsou použity jako predikce, předpokládající, že přirozeně se objevující signály (audio, fotografie apod.) obsahují vysokou míru korelace mezi následujícími hodnotami vzorků, a proto dřívější vzorky v čase, frekvenci nebo prostoru tvoří dobrou predikci současného vzorku [5]. Přenášen je poté pouze rozdíl mezi predikovanou hodnotou a původní skutečnou hodnotou, čímž dochází ke značné úspoře dat. Při dekódování dochází k totožné predikci, jejíž hodnota je následně přičtena a dochází tak k získání původní hodnoty dat. Pokud existuje velká míra korelace mezi navazujícími vzorky, bude odesílání rozdílových hodnot vyžadovat mnohem menší datový tok [5]. Bezeztrátová komprese JPEG-LS také patří mezi DPCM kompresní algoritmy, začleněné již v původním standardu JPEG. Bezeztrátový JPEG se také používá kritérium hodnocení (tzv. benchmarky) pro účely porovnávání hyperspektrálních dat. Vzhledem k tomu, že je ovšem navržen speciálně pro 2D snímky, bezeztrátový JPEG může podle [5] využívat pouze predikční pixely ze stejného řádku při použití nebo stejného pásma, v závislosti na použitém formátu. Další příklad DPCM kodéru, který byl původně vyvinut pro běžná 2D data je CALIC (Context-based Adaptive Lossless Image Coding), který využívá gradient pixelů sousedících v prostorové dimenzi, aby zvolil predikční koeficienty z předdefinovaných konfigurací. Okolní gradient je také použit při rozhodování, jaké statistické metody budou potřebné pro entropické kódování predikčních reziduálů. CALIC v upravené podobě pro hyperspektrální data používá [45] (shlukování pixelů pro predikci) a [46] (rozšíření CALIC pro třetí rozměr).

Při použití na hyperspektrálních datech se pro predikci typicky využívá lineární kombinace hodnot sousedních pixelů (ve spektrální i prostorové dimenzi). Pro praktickou implementaci hyperspektrální DPCM komprese existují určitá omezení množství dat, které může být drženo v operační paměti. Důležitým parametrem je řazení dat, používají se tři hlavní formáty, BIL (Band Interleaved By Line) – využívá všechna pásma aktuálního řádku a několik předešlých řádků; BSQ (Band Sequential) – využívá všechny řádky současného pásma a několik předchozích pásem a BIP (Band Interleaved By Pixel) [5]. DPCM používá pro bezeztrátovou kompresi například [45], algoritmus využívá fixní soubor predikčního koeficientu a Rice kódování (starší forma aritmetického kódování). Uvádějí dosažení kompresních poměrů 1.6-2.0:1 na rozdílných datech AVIRIS.

## 4.7 Metody kódování

Entropické kódování označuje [5] za konečný proces jakéhokoliv kompresního algoritmu. Zahrnuje konverzi dat produkovaných v předchozí kódovací sekci do toku binárních kódových slov. Nejčastěji používané techniky jsou Huffmanovo kódování, aritmetické kódování, RLC kódování a LZW (Lempel-Ziv-Welch) kódování. Další kódovací metody, specificky používané po vlnkové transformaci, jsou například SPIHT a EZW.

### 4.7.1 Huffmanovo kódování

Huffmanovo kódování [47] předpokládá, že pokud existuje větší počet zpráv, které mají být odeslány, než je počet symbolů, které jsou k dispozici, pak musí některá z těchto zpráv použít více než jeden symbol. Pokud tedy předpokládáme, že každý tento symbol vyžaduje pro odeslání stejnou dobu, pak čas pro odeslání celé zprávy je přímo úměrný počtu asociovaných symbolů. Během kódování jsou hodnoty dat k přenesení reprezentovány předdefinovanou abecedou symbolů nebo zpráv. Pravděpodobnost, že každá zpráva bude přenesena, je měřena a do každé zprávy je alokována specifická zpráva nazývaná kódové slovo [5]. Tato kódová slova mají rozdílné délky a nejkratší kódové slovo je alokováno ve zprávách s nejvyšší pravděpodobností, zatímco delší kódová slova jsou alokována do zpráv, které se vyskytují relativně zřídka (dochází k vytvoření binárního stromu). Tímto způsobem je průměrné množství bitů k přenesení zprávy menší, než pokud by byly všechny zprávy alokovány kódovým slovem stejné délky. Tato metoda má dvě základní nevýhody – zaprvé jsou používána kódová slova fixní a musí být známa kodéru i dekodéru, zadruhé nejmenší kódové slovo je dlouhé jeden bit. [44] proto upozorňuje, že Huffmanovo kódování nefunguje příliš efektivně, pokud je malá abeceda nebo pokud predikční část produkuje velmi malé entropické chyby.

$$\log_2(\text{pravděpodobnost symbolu}) \quad (4.11)$$

Rovnice 4.11 Délka jednoho kódového slova Huffmanova kódování.

### 4.7.2 RLC kódování

RLC (Run Length Coding) Nahrazuje dlouhé řetězce stejných hodnot (tzv. „runs“) popisem jejich četnosti [49]. Nejlepších výsledků je tedy dosaženo, pokud se hodnoty velmi často opakují, případně pokud se opakují v dlouhém úseku – [49] doporučuje použití pro obrazová data, naopak vylučuje přínos pro kompresi textu a zmiňuje podprůměrnou účinnost pro kompresi dat. V případě často se měnících hodnot dat může naopak dojít k nárůstu objemu dat.

### 4.7.3 Aritmetické kódování

Aritmetické kódování označuje [5] za entropickou technikou, která umožňuje zprávy o velmi frekventovaném výskytu kódovat s průměrně méně než jedním bitem na zprávu. Dosahuje toho tím, že zprávy k odeslání považuje za fixní skupiny a přiřadí jedno konkrétní kódové slovo, které popisuje určitou kombinaci zpráv, jež se objevují ve skupině. Tímto způsobem může být například skupina deseti zpráv o vyšší pravděpodobnosti přenesena kódovým slovem o délce deset a méně bitů. Aritmetické kódování typicky přepočítává statistiku dat během kódovacího procesu, a proto se může adaptovat k případným změnám každé zprávy. Nevýhodou je komplexnější výpočet, který však [48] označuje za vhodnější pro moderní architekturu počítačů a upřednostňuje jeho modifikovatelnost.

### 4.7.4 LZV kódování

LZV algoritmus je podle [49] vystavěn kolem tabulky řetězců, která mapuje vstupní řadu binárních hodnot do kódů fixní délky. Dále hledá sekvence hodnot, jež se opakují a pokusí se je použít tak často, jak jen to je možné [50] – vytváří tak slovník, nevytváří však separátně umístěnou kódovou knihu, spíše se snaží odkazovat na minulá data, která obsahovala shodu a tuto shodu detailně popisuje (délka shody a místo, na které je potřeba v kódu „skočit“) [51]. Algoritmus na rozdíl od RLC kódování velmi účinný pro kompresi textových dat.

### 4.7.5 EZW

EZW je podle [52] založeno na předpokladu, že pokud je koeficient v daném pásmu méně signifikantní, pak ostatní koeficienty o stejných souřadnicích na vyšších frekvencích budou zřejmě také malého významu. Všechny tyto koeficienty jsou pak kódovány společně jediným zerotree symbolem. Pokud je koeficient označen za signifikantní, zbylé bity budou odeslány na výstup algoritmu během upřesňujícího kroku, označovaném jako refinement pass. Detailní informace o tomto algoritmu lze nalézt v původním článku Sapiro [53]. Výhodou je podle [54] absence fáze trénování, kódových knih a dalších doplňkových informací.

### 4.7.6 SPIHT

SPIHT (Set Partitioning in Hierarchical Trees) je označován za nástupce algoritmu EZW, který zdokonaluje [5]. Hlavním principem dle článků [17] a [54] je částečné řazení koeficientů sestupně dle jejich magnitudy, pomocí řadících algoritmů, řazení spektrálních řezů a využívání podobnosti mezi rozdílnými měřítky mezi různými vlnkovými transformacemi. K alokovaní dostupných bitů dochází mezi kódováním mapy stromu a signifikance. Komprimovaný snímek je progresivně komprimován přímo během přenosu. SPIHT se také používá ve variaci STW, jež podle [54] využívá jiné řazení výstupu a také využívá model stavů a přechodů.

## 5. Hodnocení kompresních metod

Pokud používáme při zpracování hyperspektrálních dat ztrátovou kompresi, musíme zároveň navrhnout systém hodnocení, abychom byli schopni kontrolovat dopady komprese a kvantifikovat míru zkreslení, jež do původních dat zanášíme. Mnohé zdroje se shodují ([8],[7],[55],[5] a další), že stále nedošlo k definování přesvědčivé metriky, na kterou by se dalo spoléhat při všech různých aplikacích. Jedinou alternativou jsou přímá pozorování, která jsou však pro rozsah hyperspektrálních dat nereálná. První řešení, které se nabízí, je posuzování na základě statistických veličin hodnocení kvality distorze, mezi něž například patří SNR, PSNR nebo MSE. Trendem, jímž se porovnávání kvality ubírá, směřuje vstříc automatizovanému testování a hledání anomálií [15]. Dalším způsobem, který by přispěl k dobrému hodnocení dopadu komprese hyperspektrálních dat by podle [15] byla aplikace spektrální defragmentace. Řešíme tedy několik separátních problémů – jak porovnat různé algoritmy mezi sebou a jak získat detailní hodnocení dopadu na cílené aplikaci. V ideálním případě by byly tyto problémy sloučeny, ale vzhledem k velkému množství dostupných algoritmů a počtu známých aplikací je vhodnější spoléhat na jednodušší metody porovnání. Dále je třeba dbát na fakt, že hyperspektrální obrazová data obsahují velké množství pixelů na širokém rozsahu hodnot, artefakty výpočtu tak mohou být signifikantní, pokud se akumulují milióny malých chyb [15].

### 5.1 Používané parametry

#### 5.1.1 Míra zkreslení

Při rekonstrukci dat může být přesnost výsledků pouze tak přesná, jako je věrnost rekonstruovaných dat. Většina aplikací stále není zdokonalená a vyžaduje co největší možnou přesnost. Klíčem k optimalizaci je identifikace míry zkreslení, které je během procesu kódování do dat zanášeno. Tuto míru zkreslení následně můžeme podle [5] v případě ztrátové komprese využít pro další rozhodování, která data si můžeme dovolit ztratit a která nikoliv. [55] však dále upozorňuje, že na rozdíl od hodnocení kvality běžného záznamu není možné zkreslení hodnotit subjektivně skupinou pozorovatelů. Již HVS (viz kapitola 2.2) označuje oko za nedokonalý aparát, který je možné využít pro zkoumání běžných obrazových dat, nikoliv však pro hodnocení dat pro vědecké účely – chyba nepostřehnutelná lidským okem může mít signifikantní vliv na data z hlediska kvantitativní analýzy.

Zdroj [5] vylučuje, že v dohledné době dojde k vyvinutí standardizovaných metod pro měření zkreslení po kompresi hyperspektrálních dat a doporučuje použít alespoň dostatečné řešení, za které označuje standardizované metody SNR, MSE a PSNR. Za jejich možné nástupce pak [56] označuje PMAD a PMAE, veličiny absolutní míry maximálního zkreslení, jejich použití doporučuje i [5].

### 5.1.2 SNR

Poměr signálu ku šumu (signal-to-noise ratio) se stal velmi oblíbenou metrikou hodnocení kvality dat, definován byl již v šedesátých letech minulého století. Komunikační teorie [57] udává, že SNR je ve své nejjednodušší formě definováno jako poměr výkonu signálu ku výkonu šumu, vyjádřený v dB. Poměr vyšší než 1:1, tedy vyšší než 0 dB, udává přítomnost většího množství signálu než šumu na pozadí. Parametry poměru signálu ku šumu, šířka pásma a kapacita kanálu patří do skupiny parametrů, definovaných Shannon-Hartlyho teorémem (viz Rovnice 5.1). Ten udává maximální míru informace, která může být přenesena komunikačním kanálem zadané šířky pásma za přítomnosti šumu [58] [59].

$$C = B \log_2 \left( 1 + \frac{S}{N} \right) \quad (5.1)$$

**Rovnice 5.1 Shannon-Hartleyho teorém.**

*C je kapacita kanálu [ $\frac{\text{bit}}{\text{s}}$ ], B je šířka kanálu [Hz], S je průměrný výkon přijatého signálu [W], N je průměrný výkon šumu a interference v celé šířce pásma [W],  $\frac{S}{N}$  je poměr signálu ku šumu [-].*

### 5.1.3 MSE

MSE zastává již více než 50 let dominantní postavení na poli hodnocení kvality signálových systémů [60]. Využívá se pro porovnávání metod signálového zpracování, systémů a navrhování kompresních algoritmů. To vše navzdory obecně známým nedostatkům, kterým je věnovaná práce [60]. Bohužel, tyto nedostatky vyplynou na povrch až při jeho nahrazení subjektivními testy člověkem. Bylo prokázáno, že při zanesení určitého typu zkreslení nebo šumu do původního obrazu mohou některé úpravy při velké hodnotě MSE vykazovat minimální rozdíl oproti originálu a jiné se jevit jako zcela nepoužitelné, ačkoliv hodnota MSE zůstává malá. Stejný jev při použití MSE coby nástroje měření zkreslení zmiňuje i [5], poukazuje, že minimalizace hodnoty MSE může stále ústít ve velmi očividné vizuální artefakty, pokud jsou všechny chyby koncentrovány na malé, ale významné, ploše obrazu. Nepoužitelnost měření zkreslení pomocí MSE může být také ověřena tím, že dokonalá rekonstrukce s posunem jednoho pixelu v jakémkoliv směru vede k vysokému MSE, aniž by pozorovatel viděl jakoukoliv degradaci kvality.

Další slabou stránku MSE popisuje [62], zmiňuje silnou závislost na škálování dynamiky obrazu. MSE o hodnotě 100 8bitového obrazu ( $8 \text{ bit} = 2^8 = 256 \text{ hodnot} = 0 \text{ až } 255$ ) má velmi špatnou kvalitu, ačkoliv MSE stejné hodnoty, naměřené na 10bitovém obrazu ( $10 \text{ bit} = 2^{10} = 1024 \text{ hodnot} = 0 \text{ až } 1023$ ) je téměř nepostřehnutelné. Navzdory tomuto se zdroje ([7],[8],[55],[5],[15]) shodují, že MSE (společně s PSNR) i nadále zastává na poli posuzování kvality dominantní postavení.

Cílem MSE je porovnat dva signály pomocí kvantitativního hodnocení, které reprezentuje stupeň podobnosti, nebo úroveň obsažené chyby/zkreslení vůči originálu. Obvykle se jeden ze signálů považuje za přímý originál, druhý za verzi kontaminovanou chybami a zkreslením [61].

Nechť  $X$  a  $Y$  jsou dvě matice o rozměrech  $N \times M$ , reprezentující dva finitní diskretní signály, konkrétně kanál luminance  $X$  referenčního obrazu, respektive  $Y$  kanál komprimovaného obrazu. MSE je pak definován (viz Rovnice 5.2). Čím více se matice  $Y$  podobá matici  $X$ , tím menších hodnot MSE nabývá [61]. Pokud je výsledná hodnota 0, matice jsou identické. Rovnice 5.3 popisuje upravený vztah pro dva hyperspektrální snímky.

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad (5.2)$$

**Rovnice 5.2** Obecná definice výpočtu MSE.

*Kde  $x$  a  $y$  jsou dva diskretní finitní signály,  $N$  je délka signálu (počet vzorků).*

$$MSE = \frac{1}{I \times J \times K} \sum_{i=0}^{I-1} \sum_{j=0}^{J-1} \sum_{k=0}^{K-1} [X(i, j, k) - Y(i, j, k)]^2 \quad (5.3)$$

**Rovnice 5.3** Výpočet MSE pro dva hyperspektrální diskretní snímky  $X$  a  $Y$ .

*Kde  $X$  a  $Y$  jsou zkoumané hyperspektrální matice;  $I, J, K$  je počet řádků, sloupců a spektrálních kanálů;  $i, j, k$  jsou souřadnice pixelu.*

#### 5.1.4 PSNR

Do výpočtu parametru PSNR je zahrnut i maximální počet hodnot, jež může každý pixel nabývat, neboli bitovou hloubku, v níž je obraz kódován [10]. Ze vztahu (viz rovnice Rovnice 5.4) je evidentní, že je parametr vychází v dB, při nulové hodnotě MSE se PSNR limitně blíží nekonečnu – tedy čím vyšší hodnoty PSNR nabývá, tím je rekonstrukce věrnější původním datům. [61] označuje PSNR za vhodné pro porovnávání obrazů o různých dynamických rozsazích, kromě toho však neobsazuje ve srovnání s MSE žádnou novou informaci.



$$PSNR = 10 \log_{10} \left( \frac{L^2}{MSE} \right) \quad (5.4)$$

**Rovnice 5.4** Definice výpočtu PSNR.

*Kde  $L$  je maximální počet hodnot, jež může každý pixel nabývat.*

Vzhledem k tomu, že je parametr PSNR definován pomocí dříve zmíněného MSE (viz kapitola 5.1.3), sdílí jeho nedostatky, ani PSNR tedy není ideálním parametrem, další nevýhodou je vyjádření síly signálu jako  $L^2$ , namísto skutečné hodnoty síly signálu zkoumaného obrazu [62]. Je vhodné pro porovnávání důsledků komprese na jednom konkrétním obrazu.

### 5.1.5 Entropie

Entropie je podle [42] statistickou veličinou náhodnosti, může být použita pro charakterizování textury obrazových dat – definuje minimální počet bitů, jež je potřebný pro ztrátový popis informace (tedy největší akceptovatelná míra komprese).

$$Entropie = - \sum_k^K \sum_i^I \sum_j^J p(i, j, k) * \log_2 p(i, j, k) \quad (5.5)$$

**Rovnice 5.5** Definice entropie trojrozměrných dat obrazových dat.

*$P$  je pravděpodobnost výskytu konkrétní intenzity voxelu o souřadnicích  $(i, j, k)$ ,  $I, J, K$  je počet řádků, resp. sloupců a spektrálních řezů snímku.*

### 5.1.6 Křížová spektrální korelace

Pojem křížové spektrální korelace zmiňuje [15], dokazuje jím dobrou korelovatelnost určitých skupin spektrálních pásem a naopak nekorelovatelnost jiných. Jiné zdroje [55] a [8] se tomuto termínu vyhýbají, avšak upozorňují na větší efektivitu 3D kompresních algoritmů po vhodném přeřazení spektrálních pásem tak, aby dobře korelovatelná pásma tvořila sousední bloky. Přesně pro tyto účely může posloužit právě křížová spektrální korelace. Normovaný výpočetní vztah zmiňuje [63], s drobnými úpravami (viz Rovnice 5.6) byl realizován a použit (viz kapitola 7.4). Je nutné brát v úvahu extrémní výpočetní náročnost tohoto výpočtu, dochází totiž k porovnávání hodnot každého voxelu každého spektrálního řezu s každým voxelem všech ostatních spektrálních řezů (pro matici  $\mathbf{G}(300,300,200)$  je celkem zapotřebí  $300 \cdot 300 \cdot 200 \cdot 200$  smyček výpočtů). Výpočet pro běžný satelitní snímek tak může trvat i několik desítek minut (viz kapitola 7.4). Tento fakt činí výpočet nepoužitelným pro aplikace založené na nízké komplexitě. Může být však použit pro úvodní analýzu dat a vytvoření šablony, zůstává-li povaha dat velmi podobná i při dalších měřeních (například snímání stejné oblasti).

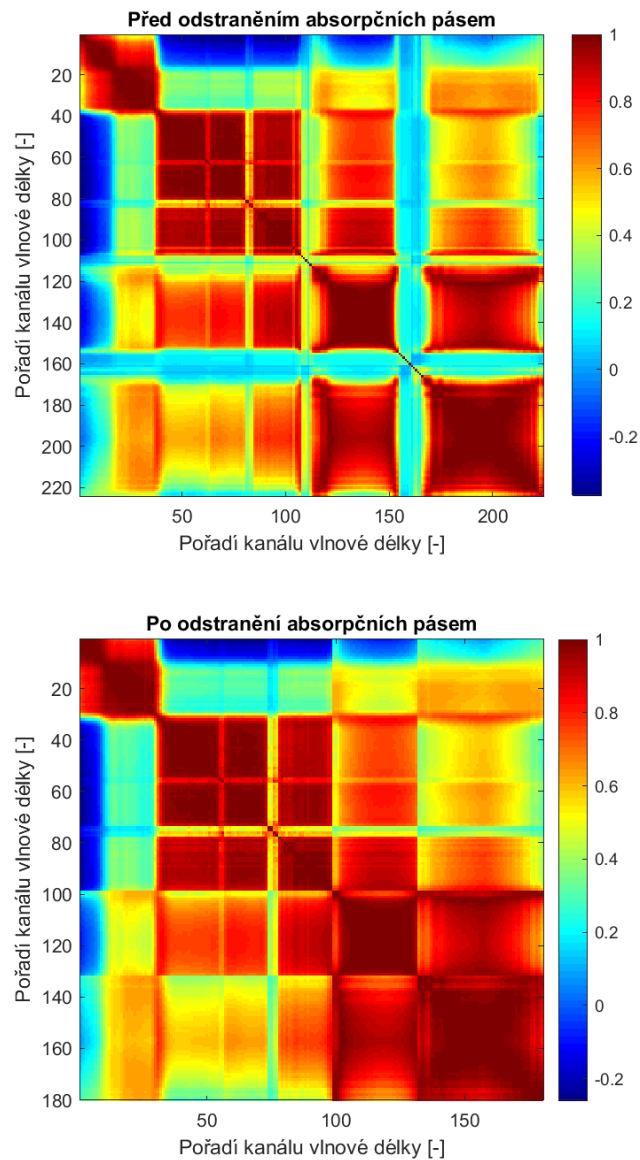
Na obrázku (viz Obrázek 5.1) je zobrazená vypočítaná křížová modulace před a po odstranění absorpčních pásem (viz kapitola 7.3.4).

$$NCC(k, l) = \frac{\sum_{i=1}^I \sum_{j=1}^J \{ [G_i(i, j) - \bar{G}_i] \cdot [G_j(i, j) - \bar{G}_j] \}}{\sqrt{\sum_{i=1}^I \sum_{j=1}^J \{ [G_i(i, j) - \bar{G}_i] \}^2} \cdot \sqrt{\sum_{i=1}^I \sum_{j=1}^J \{ [G_j(i, j) - \bar{G}_j] \}^2}} \quad (5.6)$$

**Rovnice 5.6 Výpočet normalizované křížové korelace trojrozměrné matice  $\underline{G}$ .**

Kde  $\bar{G}$  trojrozměrná matice o rozměrech  $(I, J, K)$ ,  $k, l$  jsou aktuálně porovnávané spektrální řezy,  $G_i(i, j)$  je hodnota intenzity pixelu na souřadnicích  $(i, j)$  spektrálního řezu  $i$ ,  $\bar{G}_i$  průměrná hodnota intenzity řezu  $i$ .

Normalizovaná spektrální křížová korelace



**Obrázek 5.1 Křížová spektrální korelace před a po odstranění absorpčních pásem vody.**

*Pozn. testováno na finálním testovacím souboru  $512 \times 512 \times 180$  (viz kapitola 8).*

## 6. Veřejně dostupná hyperspektrální data

### 6.1 NASA

#### 6.1.1 Aviris

Aviris je akronym pro vzdušný spektrometr v pásmu viditelných frekvencí a infračerveného záření (Airborne Visible InfraRed Imaging Spectrometer). Jde v oblasti dálkového snímání dat o velmi vážený a uznávaný nástroj, který je unikátní tím, že poskytuje kalibrované snímky v separátních 224 spektrálních kanálech (pásmech) s vlnovou délkou zhruba od 400 do 2 500 nm [11]. Na rozdíl od jiných známých hyperspektrálních snímačů není umístěn na satelitu, nýbrž na palubě letadla. Těch bylo za dobu provozu použito několik typů – NASA ER-2, Twin Otter International Turboprop, Scaled Composites Proteus and NASA WB-57. ER-2 snímal ve výšce zhruba 20 km nad mořem v rychlosti kolem 730 km/h, Twin Otter ve výšce 4 km rychlostí 130 km/h. Hlavním cílem projektu Aviris je identifikace, měření a monitorování složek povrchu Země a atmosféry, založených na molekulární absorpci a spektrální otiscích [14]. Výzkum je převážně cílen na pochopení procesů, jež souvisí s životním prostředím a klimatickými změnami.

Data jsou dostupná datovém portálu [64], jehož rozhraní je koncipováno jako interaktivní webová mapa. Uživatel specifikuje základní parametry akvizice snímku, mezi něž patří datum pořízení, lokace pořízení, úhel přeletu, velikost pixelu a po filtrování zobrazených výsledků si na interaktivní mapě vybere požadovaný lokátor pořízení. V nabídce, která se uživateli objeví, jsou doplňkové informace o oblačnosti a přesné velikosti konkrétního snímku. Rozlišení prostorové dimenze snímku bývá zhruba 2 až 16 Mpx (tedy 0,5 až 3,5 Gpx po vynásobení počtem spektrálních kanálů) a celkový objem dat zhruba je 1-2 GB pro každý snímek. Snímky jsou předzpracovány – korekce úhlu, delší strana snímku je vždy vázána k vertikální ose y, nezávisle na směru letu. Dále má uživatel možnost stáhnout si malý RGB náhled ve formátu JPEG (viz Obrázek 7.1). V případě potřeby má uživatel také možnost přístupu k letovým deníkům daného přeletu, které obsahují přesnější informace o počasí a souřadnicích počátku a konce snímání. Po rozbalení staženého archivu má uživatel k dispozici 17 souborů, mezi nimiž kromě samotného hyperspektrálního snímku jsou instrukce, popis snímání a aplikovaných technik předzpracování. Hyperspektrální snímek je rozložený na soubory HDR, obsahující důležitá metadata – velikost pixelu, úhel rotace, souřadnice, rozlišení, snímané vlnové délky; obrazová data jsou obsažena v souboru bez přípony. Zmíněným rozlišením se myslí počet vzorků liniové akvizice, tedy počet řádků (výška prostorové dimenze), počet sloupců (šířka prostorové dimenze) a počet snímaných frekvenčních pásem (hloubka spektrální dimenze). Pro vybraný snímek bylo

toto rozlišení 3428×744×224 px. Naměřené hodnoty jsou zaznamenány v celočíselné 16bitové formě, řazení BIP, big endian. Kód programu pro načtení hyperspektrálních dat Aviris je v příloze.

Data v sousedních pásmech mají obvykle velkou míru korelace, přičemž větší míry korelace je dosaženo ve spektrální dimenzi než v prostorové dimenzi. Případná kompresní metoda tedy musí tento fakt vzít v úvahu a správně ho využít. Data samotná jsou generována ve formě prokládaných pásem (band-interleaved), což má podle [45] dva efekty. Zaprvé dochází k přetrvávajícím systematickým statistickým kolísáním. Ta se mění cyklicky, protože pásmové průměry a standardní odchylky se výrazně mění mezi jednotlivými pásmy v rámci konkrétního řádku, ačkoliv stejné změny mohou být mnohem menší v rámci několika řádků. Zadruhé vnitřní šum snímajícího zařízení se také mění cyklicky, protože je rozdílný v rámci pásem, avšak konstantní mezi řádky. Cyklickým odchylkám se lze vyvarovat pomocí zpracování obrazových pásem po řádcích – pracovat s nimi jako pásmově-sekvenčními daty. To však není vhodné pro kompresi v reálném čase.

Počet řádků [-]	Počet sloupců [-]	Počet pásem [-]	Bitová hloubka [bit]	Rozsah vlnových délek [nm]	Velikost pixelu [m]	Velikost souboru [GB]
3428	744	224	16	360-2500	16,8	1,06

Tabulka 6.1 Parametry zkoumaného hyperspektrálního snímku Aviris.

Zpracování nasnímaných dat začíná v okamžiku stahování dat. Všechna data jsou ukládána v celočíselné 16bitové formě a jsou ve skutečnosti zrcadlově obrácená. Před ukládáním na RAID matici dochází ke korekci dat, uložená data už jsou poté správně orientovaná. Archivační proces také kompiluje informace o snímku, navigaci atd. A ukládá je do SDS databáze. Následuje evaluační proces PEP (Performance Evaluation and Planning), který vyhodnocuje, jestli nedošlo k určitému poškození. Během tohoto procesu jsou rovněž vytvořeny RGB náhledy [14]. Finální data L1B jsou orthokalibrovaná (konverze do jednotek radiance, na rozdíl od bezrozměrných čísel Aviris) – každý pixel prochází individuálním raytrackingem, během něžž je učiněn odhad přesné pozice senzoru a nadmořské výšky. Radiance je měřena v jednotkách mikrowattů na čtvereční centimetr na nanometr na steridián  $[\frac{\mu W}{cm^2 \cdot nm \cdot sr}]$ .

Data Aviris se podle oficiální stránky [14] využívají pro charakterizaci povrchu Země a atmosféry pomocí série geometricky koherentních měření. Takto naměřená data mohou být použita při oceánografických, environmentálních, geologických, vulkanologických, půdních, zemědělských, limnologických a dalších studiích. Další typ využití je kontinuální pozorování – například monitorování ropných skvrn, toxického odpadu a jiného znečištění.

## 6.2 USGS

USGS je akronymem pro United States Geological Survey (geologický výzkum Spojených států) a jde o vládní agenturu, součástí struktur Ministerstva vnitra [19]. Cílem této agentury je studie zemského povrchu Spojených států, přírodních zdrojů a enviromentálních hrozeb, jako je znečištění vodních zdrojů atd. Hlavními disciplínami výzkumu je biologie, geografie, geologie a hydrologie. Mezi konkrétní zkoumané oblasti patří zemětřesení, hydrologie, dálkové snímání, sopečná činnost a půdní sesuvy. Pro oblast dálkově snímaných dat platí USGS za vůbec největší archiv těchto dat na světě, schraňuje totiž všechna data ze satelitů Landsat, GloVis, Sentinel a další.

### 6.2.1 Landsat8

Zpracování dat ze satelitu Landsat 8 je uživatelsky mnohem přívětivější. Existuje totiž volně dostupná aplikace Landsat8 Data Explorer [65], která uživateli přímo v rozhraní MATLAB umožňuje na interaktivní mapě definovat oblast zájmu, v níž aplikace následně vykreslí místa pořízení satelitních snímků. Ty lze podobně jako snímky Aviris filtrovat podle data pořízení, míry oblačnosti apod. Po zvolení konkrétní oblasti se zobrazí konkrétní informace o pořízeném snímku, tedy číslo snímku, nadmořská výška a šířka pořízení, datum akvizice a odkaz ke stažení těchto dat. Aplikace Landsat8 Data Explorer dále umožňuje přímo v rozhraní nabídnout úpravy typu zvýšení kontrastu, ekvalizace, analýza vegetace, pan sharpening, NDVI atp. Velkou výhodou této aplikace je to, že uživatel nestahuje žádná data, vše probíhá online přes server Amazon [66]. Struktura dat je oproti datům Aviris velmi odlišná. Obrazová data jsou ve formátu TIFF a metadata ve formátu IMD. Nasnímaná data jsou dále rozdělena podle daných pásem vlnové délky do jedenácti snímků. Pro účely analýzy byl použit snímek [67].

Počet řádků [-]	Počet sloupců [-]	Počet pásem [-]	Bitová hloubka [bit]	Rozsah vlnových délek [nm]	Velikost pixelu [m]	Velikost souboru [GB]
5000	5000	7	16	435-2294	30	0,270

Tabulka 6.2 Parametry zkoumaného multispektrálního snímku Landsat8.

V případě, že uživatel nemá k dispozici potřebné programové vybavení, nebo ho nechce využít, jsou data dostupná na serveru USGS [19], kde je možné vyhledávat na základě definovaných kritérií (lokace, datum, míra oblačnosti, procento černých okrajů atd.). Data se stáhnou v podobě archivu, jež obsahuje číslovanou sekvenci snímků ve formátu tiff, metadata ve formátu hdr a malý JPEG náhled v RGB. Načtení do prostředí MATLAB je pak možné pomocí navrženého skriptu (viz příloha B).

## 6.2.2 Hyperion

Hyperion EO-1 (Earth Observing) byl satelit NASA, dnes již vyřazen z provozu. Délka jeho mise měla původně být 1 rok, nakonec však byl v provozu od roku 2000 až do roku 2017. Nyní je na sestupné orbitě a předpokládá se, že shoří v atmosféře během roku 2056 [68]. Jak již bylo stručně zmíněno v kapitole 3, měl za cíl prokázat využitelnost hyperspektrálních dat, mezi konkrétní cíle patřilo monitorování sopečné aktivity a Amazonského pralesa. Svou důležitost ukázal však i při zkoumání příčin a důsledků hurikánu Katrina, úniku metanu v severní Karolíně, nebo útoku na WTC 2001.

Počet řádků [-]	Počet sloupců [-]	Počet pásem [-]	Bitová hloubka [bit]	Rozsah vlnových délek [nm]	Velikost pixelu [m]	Velikost souboru [GB]
3351	1001	242	16	355-2577	30	1,51

Tabulka 6.3 Parametry zkoumaného hyperspektrálního snímku Hyperion EO-1.

Data jsou opět dostupná na serveru USGS [19] (viz. kapitola 6.2.1). Ve staženém balíku dat má uživatel k dispozici obrazová data ve formě sekvence snímků ve formátu tiff, snímek ve formátu L1R (podobně jako data Aviris viz kapitola 6.1.1) a metadata ve formátu hdr. Načíst data do programu MATLAB lze pomocí navrženého skriptu (viz příloha B).

## 6.2.3 Sentinel

Satelit Sentinel poskytuje ze všech zkoumaných hyperspektrálních senzorů největší rozlišení prostorové dimenze a nejnižší počet spektrálních kanálů. Je zároveň nejnovější, do provozu byl uveden v roce 2015 a plánovaná doba mise je 7 let [69]. Celkem měří 13 spektrálních kanálů, nicméně některé z nich (2,3,4,8,11,12) mají jiné rozlišení prostorové dimenze, nelze je tedy použít pro sestavení datové krychle. Hlavním cílem mise je zemědělské monitorování, dále monitorování sopečných erupcí, půdních sesuvů a mapování průběhu humanitárních aktivit. Data jsou stejně jako v případě (6.2.1 a 6.2.2) dostupná na serveru USGS [19]. Ve staženém balíku se tentokrát ovšem nachází kompletní datová struktura, podobná například multimediální kartě fotoaparátu. Samotná obrazová data jsou dostupná jako sekvence snímků ve formátu jp2 a metadata ve formátu xml.

Počet řádků [-]	Počet sloupců [-]	Počet pásem [-]	Bitová hloubka [bit]	Rozsah vlnových délek [nm]	Velikost pixelu [m]	Velikost souboru [GB]
5490	5490	6	20	442-2185	30	0,200

Tabulka 6.4 Parametry zkoumaného multispektrálního snímku Sentinel.

## 7. Testovaná data

### 7.1 Příprava dat

Bezpočet vědeckých publikací upozorňuje, že před návrhem experimentu a započítím měření je potřeba být podrobně seznámen s povahou dat a mít dostatečné teoretické znalosti pro správné zvážení dílčích kroků. Při zpracování hyperspektrálních dat tento fakt platí dvojnásob, jak zdůrazňuje [7]. Chyby, byť zdánlivě malé a bezvýznamné, jež provedeme v prvních krocích, prostoupí do všech následujících kroků a ovlivní všechny následující operace. Z malého zkreslení na začátku tak nakonec mohou vyústit naprosto nepoužitelná data na konci řetězce. A to navzdory tomu, že zbylé operace byly navrženy bezchybně. Konstrukce kompresních systémů byla provedena blokově – všechny bloky jsou nahraditelné, uživateli se tak nabízí velký počet kombinací. Je ovšem třeba zajistit, aby vstupní data byla co nejrelevantnější a zbavená neužitečné informace, jež by měla zbytečně negativní dopad na výkon navržených algoritmů.

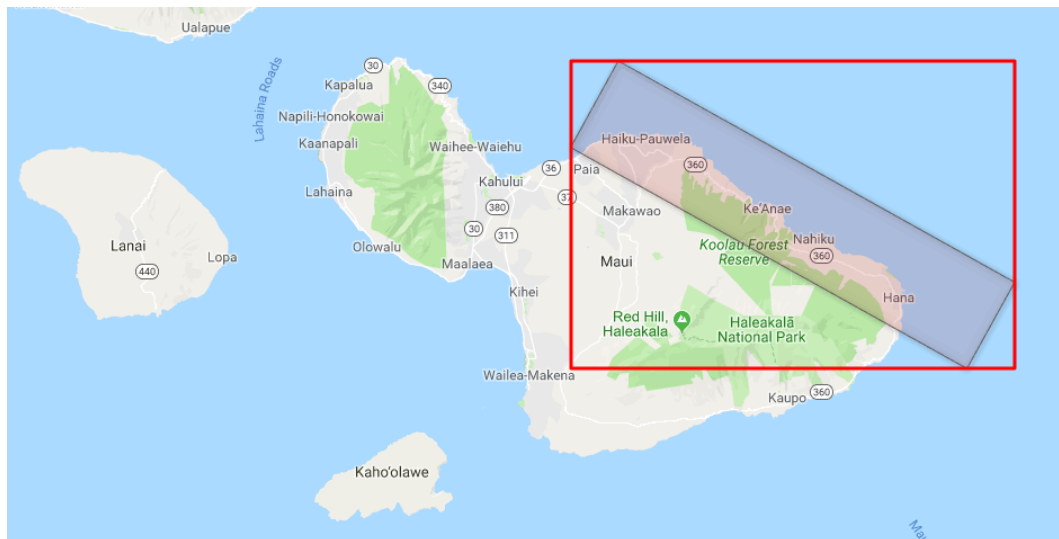
### 7.2 Aviris

Ačkoliv byly všechny dílčí bloky zkoušeny separátně na různých datech (Hyperion, Landsat, Sentinel, testovací množiny KSC a Salinas), finální návrhy budou testovány pouze na datech Aviris. Důvodem je zejména časová náročnost výpočtů a velké množství produkovaných dat. Po správném načtení vstupních dat do programu MATLAB jsou všechna data z pohledu softwaru identická – reprezentována jako trojrozměrná matice hodnot. Jak poukazuje [32], výsledné parametry se samozřejmě budou odvíjet od vstupních dat. Záleží na míře korelace v prostorové i spektrální doméně, počtu spektrálních kanálů (který se pro různé satelitní systémy velice liší), bitové hloubce a dalších faktorech. Navržený soubor kompresních algoritmů je koncipován pro samostatnou funkčnost, nevyužívá žádných externích podpůrných programů. Čtenář ho může využít pro porovnání vlastních dat.



**Obrázek 7.1** Vybraná data – oficiální RGB náhled NASA.

*Pozn. snímek je otočen o 90° vpravo.*



**Obrázek 7.2** Mapa Maui s vyznačeným přeletem snímače Aviris.

*GPS souřadnice středu dat - 20°51'33.5"N 156°08'27.3"W*

Data, jež byla porovnáována, byla nasnímána na Maui, druhém největším z Havajských ostrovů. Výběr lokality byl čistě pragmatický – tato lokalita je sjednocením všech zkoumaných zdrojů hyperspektrálních dat – lze pro tuto lokalitu obstarat data Landsat, Hyperion i Sentinel. Data Aviris jsou však dostupná jen pro území Spojených států amerických. Ostrov má na svou velikost 1 883 [km<sup>2</sup>] obrovské převýšení, v jeho středu se totiž ční sopka Haleakala, jež sahá do výšky bezmála 3 055 m n. m. [54]. Tento fakt, společně se sopečným původem a Tichým oceánem, jež ostrov obklopuje, by měl zajistit, že hyperspektrální data budou velice různorodá a zajímavá. Konkrétní výběr dat byl učiněn selekcí – vyhledávané parametry byly stáří (rok pořízení 2018), nízká oblačnost (<10 %), nízký podíl ploch bez užitečných dat (<10 %) a vhodné situování náběru (přítomnost vodních ploch i pevniny). Těmto podmínkám vyhovoval pouze let označený f180130t01p00r24. Data jsou zajímavá i tím, že obsahují mírnou lokální oblačnost a různou aktivitu vodních ploch – od klidného oceánu uprostřed snímku, až po rozbouřené hladiny na severu a jihu. Data by tedy měla oplývat značnou diverzitou.



Let f180130t01p00r24				
Datum a čas pořízení (UTC)	Označení lokality	Rozměry [px]	Rozměr pixelu [m]	Solární Elevace, azimut a rotace [°]
1/30/2018 22:17	MAUI N 22_1	3 482×744×224	16,8	51,22; 172,07; 62

Tabulka 7.1 Detailnější parametry zkoumaných dat Aviris.

## 7.3 Analýza

### 7.3.1 Postup analýzy

Samotnému zpracování dat by podle zdrojů ([8],[7],[15],[55]) měla předcházet důkladná analýza. Vzhledem k tomu, že cílem této práce je zkoumání metod komprese dat, jsou z předzpracování vyloučeny nelineární úpravy. Cílem je na konci řetězce dosáhnout dat, jež budou co nejvěrněji reprezentovat data vstupní. Nelineární úpravy by mohly narušit vztah prostorové a spektrální dimenze. Předzpracování bylo tedy omezeno na redukci dat.

Právě redukce dat se v průběhu testování jevila jako nezbytná, protože proces zpracování velkých trojrozměrných matic je velice náročný na operační paměť počítače. Program MATLAB má bohužel nepříjemnou vlastnost, že v případě přílišného využití operační paměti se probíhající program přeruší (nedojde ke zpomalení výpočtů, ale rovnou k jejich přerušení).

Zdroje [12] a [18] upozorňují na vliv pásem absorpce vody (tedy pásma, v nichž dochází je v atmosféře přítomna vodní pára, jež absorbuje a odráží téměř veškeré elektromagnetické záření) a jejich negativní dopad na data. Oba zdroje důrazně doporučují tato data ze zkoumaných souborů dat úplně vyřadit z důvodu velmi řídkého obsahu hodnotné informace a velkého zašumění zbylých dat. Prvním zásahem bylo ořezání dat v prostorové dimenzi – byly ořezány černé okraje a příliš velká oblast hladiny oceánu ve spodní části snímku. Nadále je velikost dat 2880×704×224. Variabilní skript pro ořez hyperspektrálních dat je umístěn v příloze, umožňuje manuální ořez dat i ořez na základě grafické selekce.

## False-color RGB náhledy dat Aviris


VNIR RGB 638:580:511 [nm]



VNIR Vegetace 850:580:511 [nm]



SWIR RGB 2197:1651:1



**Obrázek 7.3 RGB náhledy v nepravých barvách (false-color) testovaných dat.**  
*Pozn. generované pomocí vlastního skriptu (součást přílohy) v programu MATLAB.*


### 7.3.2 TNTmips

TNTmips je součástí kolekce programového vybavení od firmy MicroImages, používaná pro prostorovou analýzu geografických dat. Část programu TNTmips je přímo určena pro zpracování hyperspektrálních dat, nabízí uživateli možnost prostorového vykreslení dat a jejich velmi pokročilou analýzu – od úpravy histogramu, jasů, až po filtrace a výpočty PCA komponent. Firma MicroImages poskytla pro účely této práce dočasnou licenci pro využití programu.

### 7.3.3 Hyperkrychle

TNTmips umožňuje na rozdíl od programu MATLAB vykreslení tzv. hyperkrychle (viz kapitola 2.4.3). Program ovšem není schopen přímého zpracování dat, které produkuje právě systém Aviris, protože tyto soubory jsou bezformátové, nemají žádnou příponu. Je proto nutné je nejdříve načíst do programu MATLAB a poté je exportovat jako sekvenci snímků – každé nasnímané vlnové délce odpovídá jeden snímek (tj. hloubka hyperkrychle). Tato sekvence se následně importuje do rozhraní TNTmips a konvertuje do interního formátu datové krychle (.rvc), který je poté možné nativně načíst a zobrazit. Jak již bylo zmíněno, TNTmips oplývá řádkou analyzačních nástrojů, avšak pro účely této práce bylo využito právě jen vykreslení hyperkrychle. Ve vykreslovacím rozhraní je možné asociovat specifickou barvu pro každou vlnovou délku (nebo blok vlnových délek). Pro účely vykreslení našich dat byla volena přednastavení rainbow, rainbow, 16-step a beach.

Na obrázku (Obrázek 7.4 – a) a b)) jsou zobrazeny řezy daty Aviris před redukcí spektrální dimenze. Za povšimnutí stojí například jiná barva vodní hladiny v severní a jižní části snímku. To je způsobeno vyšší oblačností, vyšším odrazem slunečního záření a nižší hloubkou oceánu. Právě hloubku oceánu lze vhodným využitím programu TNTmips dobře studovat. Dále si musíme na bočních stranách (ve spektrální dimenzi) a) a b) všimnout, že zhruba v polovině a druhé třetině jsou pásma, jež narušují spojitý průběh. Jde právě o ta pásma vodní absorpce, jež byla popsána v kapitole 6.3.1. Detailnější pohled na zmíněný jev je na obrázku (Obrázek 7.5 a) a b)), kde je vykreslen jeden řez, spadající právě do tohoto pásma. Tím je ověřeno, že tyto snímky skutečně neobsahují užitečnou informaci a mohou být odstraněny.




**Obrázek 7.4** Hyperkrychle dat Aviris.

*a) 81. vlnová délka, rainbow b) 84. vlnová délka, rainbow, řez daty c) 82. vlnová délka, odstraněná pásma absorpce*

### 7.3.4 Redukce dat

Manuální analýzou a prolisťováním jednotlivých snímků byla tyto pásma stanovena jako 0-7 (366-424 nm), 104 (1323 nm), 107-117 (1352-1452 nm), 146 (1741 nm), 152-170 (1801-1926 nm), 219 (2446 nm), 221-224 (2466-2495 nm). Tuto diskontinuitu lze ověřit i grafickým znázorněním spekter na náhodně vybraných bodech (viz Obrázek 3.2), kde jsou na těchto vlnových délkách jasně patrná lokální i globální minima. Jistě by bylo možné stanovit metodu, která by tato irelevantní data dohledala a vymazala automaticky (například nastavením určitého thresholdu PSNR, vztaženého k průměrnému snímku souboru dat), nebo využitím křížové spektrální korelace (viz kapitola 5.1.6), nicméně v závislosti na důležitosti testovaných dat a riziku odstranění užitečné informace je vhodnější provést tuto selekci manuálně. Vlnové délky, korespondující k odstraněným řezům, lze dohledat pomocí tabulky *aviris\_wavelengths.xlsx* v příloze u dat Aviris. Na obrázku (viz Obrázek 7.5 c)) jsou zobrazena data po odstranění pásem vodní absorpce. Skript redukce specifických vlnových délek je umístěn v příloze. Nadále mají zkoumaná data rozměr 2880×704×180. Prostorovou redukcí dat tedy došlo k odstranění bezmála 22 % dat, spektrální redukcí dalších takřka 20 % dat, což celkem odpovídá úspoře 37 % (vstupní data o velikosti 1 106 MB, byla redukována na 866 MB a následně na konečných 696 MB). Je důležité poznamenat, že ačkoliv došlo k větší úspoře odstraněním dat na základě prostorové analýzy, je tento krok značně subjektivní a bude se extrémně lišit podle následného použití dat (redukce dat může být naprosto vyloučena, nebo naopak být mnohem extrémnější), avšak redukce spektrální dimenze by měla být pro stejnou metodu snímání účinná vždy stejnou měrou. Takto redukovaná data prohlašujeme za připravená k testování navržených algoritmů.



Obrázek 7.5 Hyperkrychle dat Aviris – detailní náhled nespojitosti spektra.

a) řez 106. vlnové délky, rainbow b) řez 107. vlnové délky, rainbow

## 7.4 Testování


### 7.4.1 Příprava testovaných algoritmů

V úvodu plánování této práce bylo předpokládáno, že porovnávané algoritmy budou obstarány externě od autorů, kteří se věnují kompresi hyperspektrálních dat. Článků, proklamujících úspěšné navržení nového algoritmu, je veřejně dostupných několik desítek. S prosbou o poskytnutí algoritmu bylo kontaktováno zhruba 35 autorů. Bohužel došlo k odpovědi pouze autorů [32], [71] a [72]. Přičemž algoritmus navržený [71] byl závislý na placeném podpůrném programu a byl kompatibilní pouze s operačním systémem Linux; algoritmus [72] se nepodařilo dohledat a [32] se ukázal jako nekompletní a bohužel nevhodný a pro využití v této práci. Přínos se tak jevil jako nulový, avšak poznatky z analýzy posledního jmenovaného algoritmu se ukázaly jako stěžejní při sepisování vlastní verze.

### 7.4.2 DWT

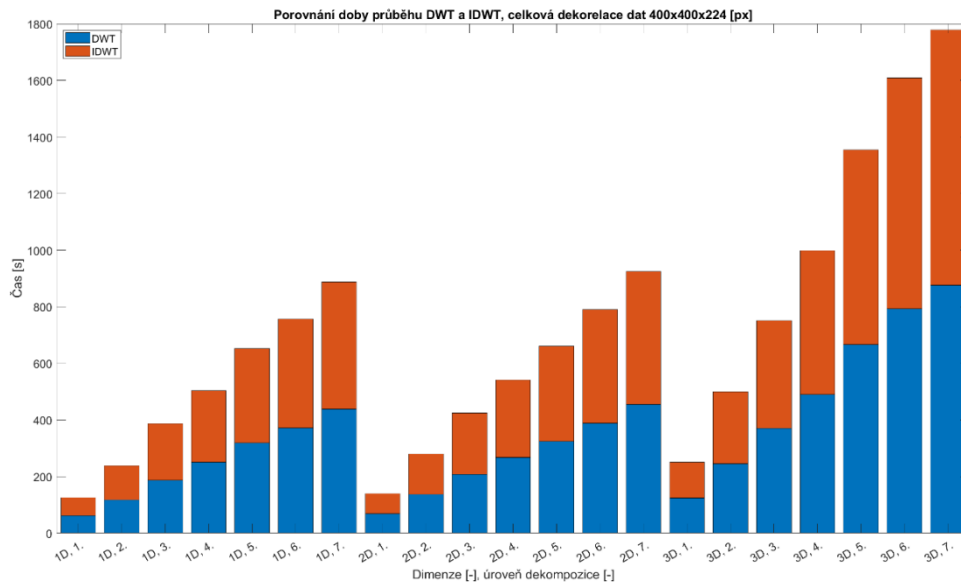
V rámci této práce došlo k navržení a realizaci 1D, 2D a 3D DWT algoritmů (viz příloha B) v prostředí programu MATLAB. 1D DWT je koncipován jako spektrální dekorelátor, 2D DWT jako prostorový dekorelátor a 3D DWT jako kombinace obou předchozích metod. Vstupem funkce je trojrozměrná obrazová matice, zvolený typ vlnky a úrovně. Úrovně je možné volit v rozsahu 1-7 a k dispozici je 7 typů vlnek, jež odpovídají typům vlnek, které jsou implementovány v programu MATLAB (Haar, Daubechies, Symlets, Biorthogonal, Reverse biorthogonal, Coiflets, Fejer-Korovkin). Jednoduchou alternací lze program uzpůsobit i pro jiné vlnky, případně vlastní koeficienty vlnkových filtrů. Všechny tři algoritmy jsou rozděleny na volající funkci a vnitřní funkci DWT, která provádí konvoluci a správné „oříznutí“ výsledného signálu tak, aby nedošlo k posunu vůči vstupnímu signálu. Je dodržena kaskádovitá struktura, stanovená v kapitole 4.4.2. Při budování algoritmu bylo vycházeno z algoritmu použitého [32], problémem bylo ovšem to, že tento algoritmus neměl definovanou inverzní transformaci a po implementaci se ukázal jako časově nepřiliš dobře optimalizovaný. Oba algoritmy (původní i optimalizovaný) jsou zahrnuty v příloze.

V první sadě testů byla použita redukovaná, náhodně vybraná data 400x400x224 px. Po zkontrolování správné funkčnosti algoritmu (viz obrázek Obrázek 7.6) došlo k testování časové náročnosti v závislosti na použité vlnce, úrovni dekompozice a dimenze DWT. Tyto testy byly učiněny pro všechny možné varianty (viz příloha B), na obrázku (Obrázek 7.7) je zobrazena časová náročnost pro různé úrovně a dimenze dekompozice, časové údaje jsou průměrem pro všechny použité typy vlnek.

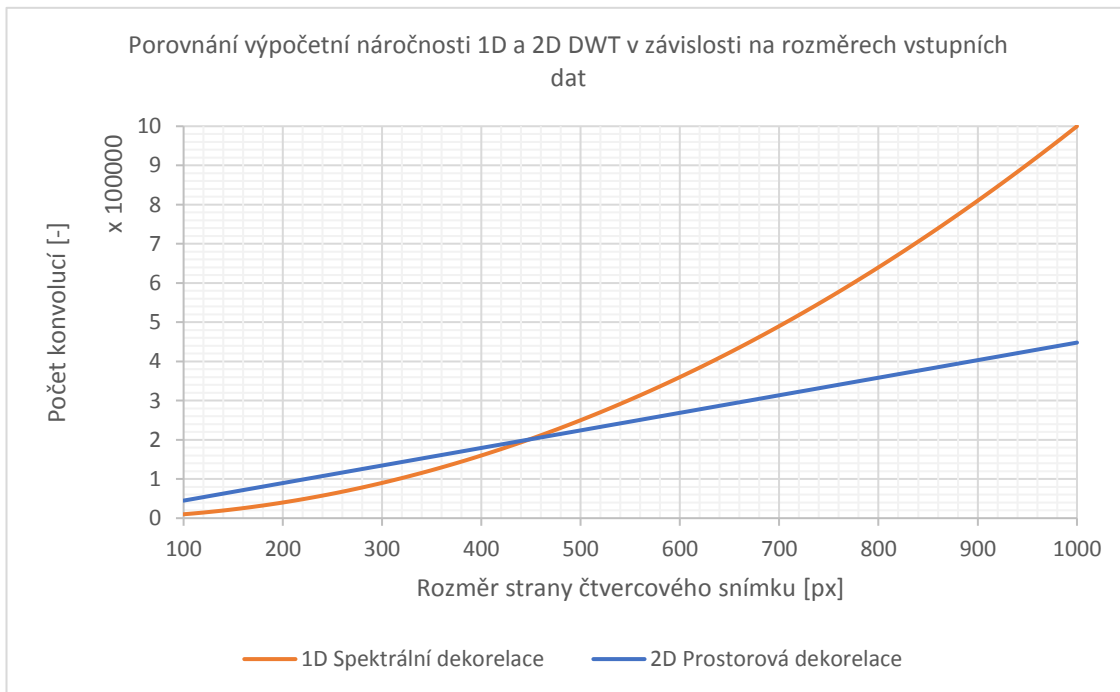


Obrázek 7.6 Průběh 3D DWT, vlnka biortogonálního typu.

Zajímavým výsledkem se může zdát fakt, že 1D i 2D dosahují téměř totožné doby výpočtu. To je dáno velikostí testovaného souboru – doba 1D DWT pro užití na dekorelaci spektrální dimenze je závislá na rozměrech vstupních dat exponenciálně, kdežto 2D DWT pro užití na dekorelaci prostorové dimenze má závislost lineární, přičemž právě při čtvercových rozměrech prostorové dimenze mezi 400-500 px je doba výpočtu 1D i 2D DWT téměř totožná (viz Obrázek 7.7). Pro velmi rozměrná data bude spektrální dekorelace časově mnohem náročnější než dekorelace prostorové dimenze. Časová náročnost trojrozměrné dekorelace je pak nepatrně nižší než kombinace obou předchozích případů. Dochází tak k jevu, kdy na testovaných vstupních datech  $400 \times 400 \times 224$  je 3D DWT 1. řádu rychlejší než 1D DWT i 2D DWT 2. řádu. Závislost 3D DWT na velikosti vstupních dat je taktéž exponenciální.



Obrázek 7.7 Závislost doby výpočtu na úrovni a dimenzi dekompozice.

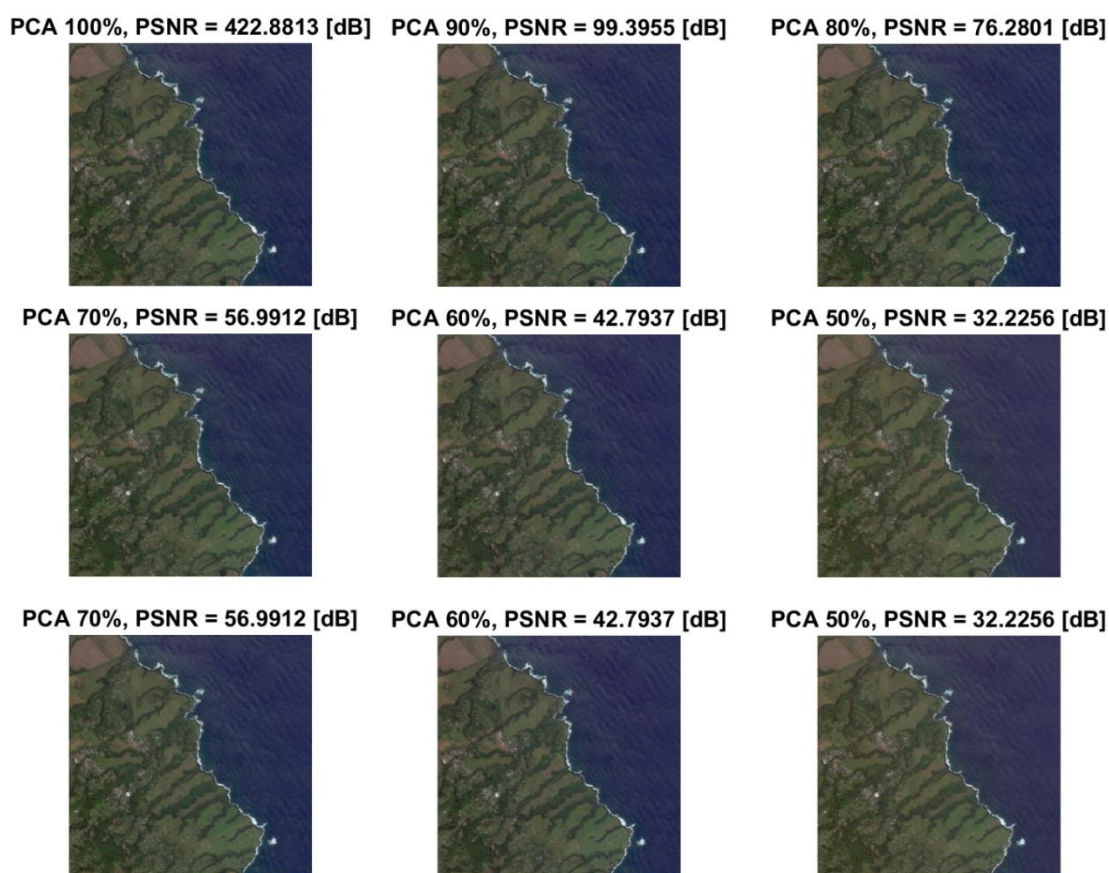


Obrázek 7.8 Výpočetní náročnost 1D vs. 2D DWT.



### 7.4.3 PCA

Při budování algoritmu PCA se vycházelo z volně dostupné příručky [37], jež je doplněná o několik vzorových kódů. Algoritmus byl upraven tak, aby byl schopen operovat bezeztrátově nebo téměř bezeztrátově – tento poměr je ovládán vstupní proměnnou, jež reprezentuje procento vlastních vektorů, které budou při transformaci použity; ostatní budou zahozeny – tímto způsobem může docházet ke kompresi přímo během transformace. Dále algoritmus upraven tak, aby byl kompatibilní s hyperspektrálními daty. Na výstupu funkce je kromě transformovaného obrazu také matice s vlastními vektory a průměrová matice – tedy data nutná pro inverzní transformaci. Jak je vidět na obrázku (Obrázek 7.9), má počet odstraněných vlastních vektorů velmi vysoký vliv na kvalitu rekonstruovaného obrazu. Pro hyperspektrální data a snahu dosáhnout bezeztrátové, či téměř bezeztrátové komprese, budeme muset využít 100 % vlastních vektorů, případně odstranit maximálně jednotky procent. Vyšší míra zkrácení není přijatelná.




**Obrázek 7.9 PCA – porovnání vlivu počtu odstraněných vlastních vektorů na kvalitu rekonstrukce.**

*Pozn. údaj v procentech udává vstupní údaj kvality kompresní metody a odpovídá počtu použitých vlastních vektorů, ostatní jsou v průběhu komprese odstraněny.*

#### 7.4.4 DCT

Pro implementování 2D DCT na hyperspektrálních datech byly pro předlohu použity programy [73] a [74], bylo však provedeno mnoho úprav. Algoritmus bylo potřeba vyladit tak, aby byl schopen práce i v téměř bezztrátovém režimu, byl tvořen separátními bloky a akceptoval hyperspektrální data. Použité funkce jsou zahrnuty do přílohy. Algoritmus je doplněn o váhovatelnou škálovací matici, mírou škálování lze ovlivnit výslednou kvalitu obrazu (Obrázek 7.10). Z výsledků je patrné, že pro účely této práce bude vhodné využít pouze téměř bezztrátový režim 100 %, bez dodatečné kvantizace. Výhodou navrženého algoritmu je, že vstupem kodéru je pouze trojrozměrná obrazová matice a vstupem dekodéru trojrozměrná komprimovaná matice (bez dalších potřebných indexačních metadat apod.).

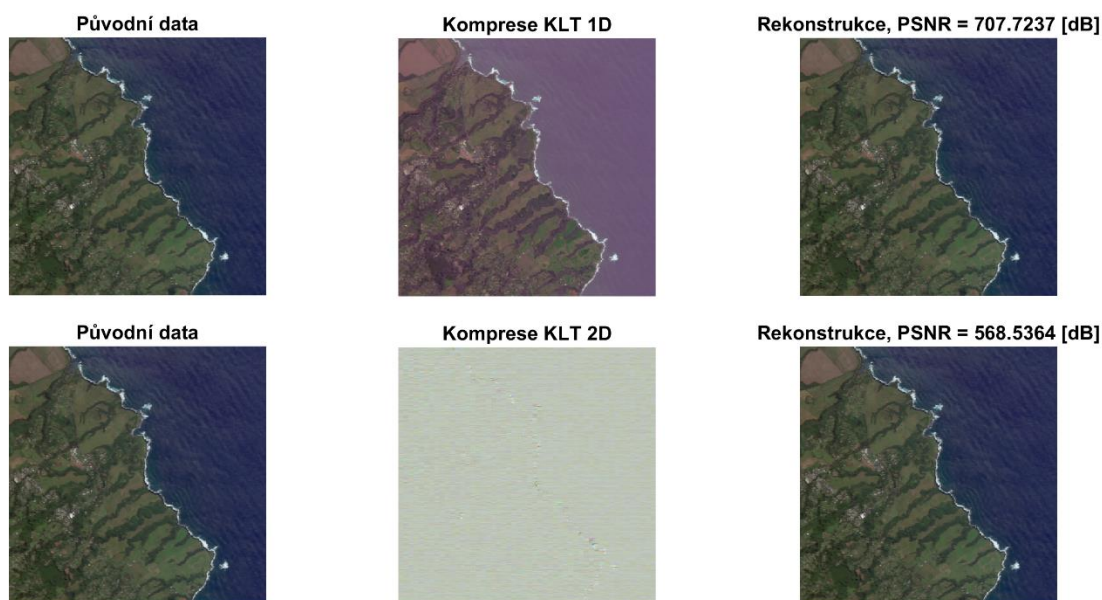


**Obrázek 7.10 DCT v závislosti na použité škálovací matici.**

*Pozn. údaj v procentech udává vstupní údaj kvality kompresní metody a odpovídá velikosti skaláru, jímž je násobena škálovací matice a přímo tak ovlivňuje, jak velký počet DCT koeficientů bude po operaci roven nule.*

### 7.4.5 KLT

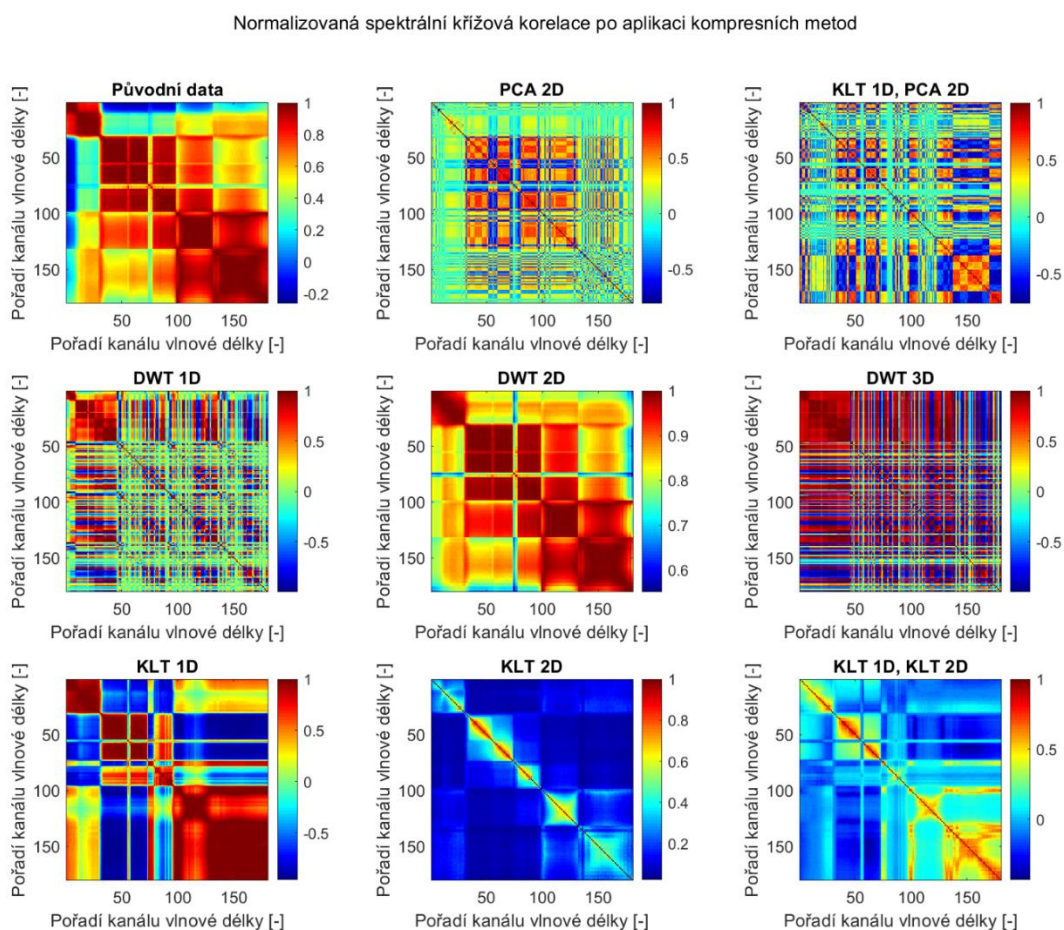
Návrh 2D KLT byl inspirován algoritmem navrženým [75] a zároveň vlastním algoritmem DCT (viz kapitola 7.4.4), opět však bylo nutné vyřešit správnou indexaci pro vstupní trojrozměrnou matici a další úpravy, aby byl algoritmus úspěšně aplikovatelný pro hyperspektrální data. Varianta KLT 1D pro účely spektrální de Korelace byla navržena na základě poznatků z KLT 2D algoritmu za přispění principů, jež byly zmíněny v příručce [37] věnované PCA kompresi (z níž KLT vychází). Testování (viz Obrázek 7.11) dokazuje minimální ztrátovost algoritmu, zřejmě pramenící z jistých omezení aplikace MATLAB.



Obrázek 7.11 KLT 1D a 2D – testování ztrátovosti navrženého algoritmu.

## 7.4.6 Křížová korelace testovaných metod

Normalizovaná křížová korelace byla měřena pro komprimovaný snímek každé testované metody, je tedy možné přímo pozorovat závislost transformací na korelaci spektrální dimenze. Níže (viz Obrázek 7.12) jsou vykresleny křížové korelace pro všechny navržené metody. Zajímavé je především přímé srovnání metod pro dekorelaci spektrální dimenze, 1D KLT a 1D DWT, obě mají na spektrální dimenzi extrémní vliv, výsledek 1D KLT ověřuje tvrzení [32] a [15], že je nejvhodnější spektrální dekorelační metodou z hlediska kompaktnosti energie.



**Obrázek 7.12** Porovnání vlivu typu komprese na korelaci spektrálních kanálů.

*Pozn. vlnkové transformace byly dekomponovány v druhé úrovni, PCA v bezztrátovém režimu (byly zachovány všechny hlavní vektory).*

## 8. Navržené kompresní systémy

### 8.1 Příprava měření parametrů komprese

Původním plánem bylo měřit redukovaná data (viz kapitola 7.3.4), avšak to se ukázalo jako nemožné. Bylo počítáno s využitím nativní funkce programu MATLAB pro kvantizaci koeficientů, funkcí `wdencmp` (viz [76]). Ta se ovšem ukázala jako velmi nevhodná, protože nevytváří žádná výstupní data po kompresi, výstupem funkce je pouze rekonstruovaný snímek a počet koeficientů, k jejichž vynulování došlo v průběhu kvantizace – lze tedy vypočítat kompresní poměr, MSE a PSNR nikoliv. Nakonec byla místo ní zvolena příbuzná funkce `wcompress` (viz příručka [77]). Ta má výhodu přímého výstupu (defaultně ve formátu .wtc) a velkého množství metod kvantizace a kódování. Nevýhodou je, že není možné ovlivňovat ztrátovost tohoto algoritmu, ten pracuje vždy v přednastaveném režimu a výkon závisí ryze na vstupních datech. Pokud je s touto neblahou vlastností předem počítáno jako v tomto případě, je možné ji využít ve prospěch pro vzájemné porovnávání různých metod a určení, která ze zkoumaných bezztrátových transformací (DWT, KLT a PCA) lépe předzpracovává data právě pro funkci `wcompress`. Dalším omezením současné verze programu MATLAB (R2018a, Wavelet Toolbox 5.0) je podpora pouze vstupních dat o shodném rozměru stran, který zároveň musí být roven mocninám čísla 2. Toto omezení je možné obejít vhodně zvolenou segmentací původních dat a následným komprimováním pouze těchto segmentů. Pro účely této práce byla zvolena přímější varianta, jíž byla další redukce zkoumaných dat. Šířka původních dat byla 744 px, největší použitelnou mocninou čísla 2 je tedy 512, data byla proto redukována na rozměr 512×512×180 px. Relativně malý rozměr dat se později ukázal jako velmi vhodný, protože doba zpracování dat je extrémně dlouhá a v případě většího rozměru by nebylo možné realizovat všechna testování.

Funkci `wcompress` samozřejmě nebylo možné bez určitých úprav. Bylo nutné navrhnout podpůrný skript, který se postará o rozklad na jednotlivé řezy vlnové délky a ty následně indexuje tak, aby bylo možné jejich zpětné rekonstruování do hyperkrychle. Změnou parametru podpůrné funkce lze volit mezi všemi nabízenými metodami komprese, těch je celkem 5 (EZW, SPIHT, STW, WDR a ASWDR). Data byla testována pouze na prvních třech jmenovaných, protože jsou využívány nejčastěji a měly by dosahovat nejlepších výsledků (viz literatura [53], [17], [54]). Zmíněná funkce obsahuje i velmi lákavou metodu 3D SPIHT, která byla rovněž zprovozněna, bohužel je však fixně uzpůsobená pro práci s RGB soubory o 8bitové barevné hloubce. Během přepočtu dochází k obrovskému zkreslení a nebyl proto dále používán. Další vyřazenou metodou je DCT na základě špatných výsledků úvodních testů v kombinaci s RLC.

## 8.2 Naměřené parametry

DWT 1D							
Úr. *	Komprese [min:s]	Dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]
EZW (Embedded Zerotree Wavelet)							
1	11:22	09:50	90	5,68	15,85:1	1,27	11,67
2	12:50	13:18	90	5,26	17,11:1	1,37	12,68
3	17:50	16:16	90	5,01	17,96:1	1,44	11,41
4	38:34	37:49	90	4,41	20,40:1	1,63	11,99
5	44:20	41:39	90	4,69	19,19:1	1,54	9,25
SPIHT (Set Partitioning In Hierarchical Trees)							
1	08:27	07:46	90	11,06	8,13:1	0,65	7,68
2	09:41	09:04	90	9,92	9,07:1	0,73	6,96
3	14:14	18:33	90	9,87	9,12:1	0,73	8,25
4	34:51	36:22	90	8,48	10,61:1	0,85	6,76
5	40:53	39:13	90	9,08	9,91:1	0,79	7,47
STW (Spatial-orientation Tree Wavelet)							
1	10:36	09:30	90	7,10	12,68:1	1,01	8,48
2	12:01	11:58	90	6,26	14,38:1	1,15	7,70
3	16:32	19:24	90	6,19	14,53:1	1,16	9,12
4	37:40	39:50	90	5,39	16,70:1	1,34	7,48
5	43:21	42:55	90	5,82	15,45:1	1,24	8,24
DWT 2D							
Úr. *	Komprese [min:s]	Dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]
EZW (Embedded Zerotree Wavelet)							
1	15:09	10:09	90	3,29	27,32:1	2,19	20,25
2	31:04	17:45	90	1,94	46,50:1	3,72	29,36
3	36:31	25:39	90	1,76	51,08:1	4,09	29,07
4	39:56	29:08	90	1,60	56,14:1	4,49	28,83
5	49:24	27:37	90	1,48	61,00:1	4,88	28,41
SPIHT (Set Partitioning In Hierarchical Trees)							
1	10:17	07:07	90	6,18	14,56:1	1,16	13,86
2	22:16	14:31	90	3,36	26,78:1	2,14	21,77
3	27:44	20:29	90	3,10	29,04:1	2,32	21,26
4	29:52	18:38	90	2,85	31,55:1	2,52	20,78
5	39:10	29:44	90	2,63	34,19:1	2,74	20,25
STW (Spatial-orientation Tree Wavelet)							
1	13:28	07:18	90	4,25	21,16:1	1,69	15,37
2	27:44	16:14	90	2,29	39,29:1	3,14	24,64
3	33:24	18:47	90	2,11	42,59:1	3,41	24,14
4	36:29	25:44	90	1,94	46,41:1	3,71	23,68
5	46:11	43:14	90	1,78	50,59:1	4,05	23,20
DWT 3D							
Úr. *	Komprese [min:s]	Dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]
EZW (Embedded Zerotree Wavelet)							
1	19:10	13:19	90	2,81	32,03:1	2,56	20,43
2	30:07	21:06	90	1,80	49,99:1	4,00	33,07
3	41:39	27:32	90	1,57	57,37:1	4,59	31,34
4	51:22	34:26	90	1,39	64,89:1	5,19	31,93
5	1:03:20	1:03:43	90	1,25	71,89:1	5,75	26,41
SPIHT (Set Partitioning In Hierarchical Trees)							
1	13:03	10:36	90	4,89	18,42:1	1,47	14,12
2	21:40	17:12	90	2,81	32,05:1	2,56	21,09
3	31:45	21:31	90	2,54	35,40:1	2,83	22,20
4	40:32	28:44	90	2,33	38,58:1	3,09	20,85
5	51:52	1:09:43	90	2,09	43,11:1	3,45	21,50
STW (Spatial-orientation Tree Wavelet)							
1	16:49	12:57	90	3,25	27,69:1	2,21	15,63
2	27:40	21:14	90	1,90	47,45:1	3,80	23,82
3	38:23	26:31	90	1,72	52,30:1	4,18	25,14
4	48:23	33:46	90	1,60	56,37:1	4,51	23,73
5	57:39	1:14:58	90	1,43	62,83:1	5,03	24,70

Tabulka 8.1 Naměřené parametry pro metody 1D, 2D a 3D diskrétní vlnkové transformace.

\* úroveň dekomprese dané vlnkové transformace

PCA 2D							
V. v. [%]*	Komprese [min:s]	Dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]
EZW (Embedded Zerotree Wavelet)							
100	36:21	18:24	90	1,32	68,31:1	5,46	57,30
50	17:54	10:57	90	1,11	81,06:1	6,48	32,26
SPIHT (Set Partitioning In Hierarchical Trees)							
100	24:24	09:53	90	2,28	39,53:1	3,16	46,35
50	10:48	05:28	90	1,99	45,15:1	3,61	29,67
STW (Spatial-orientation Tree Wavelet)							
100	32:15	12:27	90	1,57	57,19:1	4,58	53,04
50	15:01	09:30	90	1,33	67,74:1	5,42	31,30
KLT 1D							
EZW (Embedded Zerotree Wavelet)							
Doba komprese [min:s]	Doba dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]	
10:03	08:23	90	5,29	17,01:1	1,36	16,20	
SPIHT (Set Partitioning In Hierarchical Trees)							
07:10	06:45	90	10,96	8,21:1	0,66	12,42	
STW (Spatial-orientation Tree Wavelet)							
09:06	07:24	90	7,27	12,39:1	0,99	13,31	
KLT 2D							
Doba komprese [min:s]	Doba dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]	
EZW (Embedded Zerotree Wavelet)							
28:19	28:05	90	0,95	94,65:1	7,57	38,78	
SPIHT (Set Partitioning In Hierarchical Trees)							
09:38	13:03	90	1,63	55,19:1	4,42	28,05	
STW (Spatial-orientation Tree Wavelet)							
20:52	18:13	90	1,13	79,40:1	6,35	35,29	
KLT 1D, PCA 2D							
Doba komprese [min:s]	Doba dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]	
EZW (Embedded Zerotree Wavelet)							
30:40	23:28	90	1,18	76,14:1	6,09	58,86	
SPIHT (Set Partitioning In Hierarchical Trees)							
17:23	12:30	90	2,02	44,64:1	3,57	50,84	
STW (Spatial-orientation Tree Wavelet)							
26:19	17:22	90	1,41	63,61:1	5,09	58,36	
KLT 1D, KLT 2D							
Doba komprese [min:s]	Doba dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]	
EZW (Embedded Zerotree Wavelet)							
38:02	34:15	90	0,88	102,31:1	8,18	45,35	
SPIHT (Set Partitioning In Hierarchical Trees)							
29:32	19:06	90	1,48	60,73:1	4,86	33,05	
STW (Spatial-orientation Tree Wavelet)							
29:32	29:06	90	1,03	87,33:1	6,99	40,67	

Tabulka 8.2 Naměřené kompresní parametry pro metody 1D a 2D KLT, 2D PCA.

\* počet použitých vlastních vektorů, vyjádřený v procentech

Bez předzpracování							
Doba komprese [min:s]	Doba dekomprese [min:s]	Velikost před [MB]	Velikost po [MB]	Komp. poměr [-]	bpp [b]	PSNR [dB]	
EZW (Embedded Zerotree Wavelet)							
04:29	02:28	90	8,05	11,18:1	0,89	12,09	
SPIHT (Set Partitioning In Hierarchical Trees)							
02:16	01:25	90	17,56	5,13:1	0,41	7,36	
STW (Spatial-orientation Tree Wavelet)							
04:01	02:35	90	12,01	7,49:1	0,60	8,15	

Tabulka 8.3 Naměřené parametry bez aplikace jakékoliv transformace nebo metody.

### 8.3 Shrnutí výsledků

Správnou funkčnost navržených algoritmů je možné ověřit porovnáním s daty, jež nebyla vystavena žádné vstupní transformaci a byla komprimována pouze nástrojem wcompress (viz Tabulka 8.3). Vidíme, že všechny navržené metody dosahují vyššího PSNR i kompresního poměru, ovšem za cenu delší doby zpracování (v případě 3D DWT vidíme nárůst opravdu dramatický). Nejhuře si vedla metoda 1D DWT pro spektrální dekorelaci, i ta však dosahuje lepších výsledků, než samotný wcompress. Bylo by velmi zajímavé zahrnout do testování trojrozměrný nástroj kvantizace koeficientů, jímž je třeba právě 3D SPIHT. Ten by měl být schopen využít spektrální dekorelaci 1D DWT a 1D KLT mnohem efektněji, jak už ovšem bylo zmíněno, nedošlo v rámci této práce k jeho realizaci.

Předzpracování	Analýza	Výpočty parametrů	Nástroje komprese	Komprese
Načtení Aviris	Ořez hyperkrychle v prostorové i spektrální dimenzi	Normovaná křížová korelace	Formátování 3D matice do číselné řady	DWT 1D, 2D, 3D
Načtení Sentinel	Vytvoření RGB náhledů z požadovaných řezů	MSE	Segmentace 3D matice	PCA 2D
Načtení Hyperion	Ekvalizace	PSNR	Zig-zag čtení 3D matice	DCT 2D
Načtení Landsat	Adaptivní ekvalizace	Kompresní poměr	Podpůrná funkce pro wcompress	KLT 1D, 2D
Jas, kontrast	Zanesení šumu do 3D matice	Entropie	Import a export hyperkrychle	RLE

Tabulka 8.4 Souhrn navržených funkcí pro software MATLAB.

Tabulka 8.4 uvádí souhrn navržených metod komprese, analýzy a dalších zpracování multispektrálních a hyperspektrálních obrazových dat. Všechny tyto metody jsou součástí přílohy, implementované ve formě funkcí do jednoho skriptu programu Matlab (viz příloha B, složka MATLAB, soubor 'komprese\_hyperspektralnich\_dat.m').



## 9. Závěr

Praktická zkušenost se zpracováním hyperspektrálních dat ověřila předpoklad, že jde o velmi náročný proces, a to jak z hlediska náročnosti výpočtu, tak z hlediska požadavků na výstupní data (nízké zkreslení a rychlé čtení). Ačkoliv je oblast komprese hyperspektrálních dat již poměrně dobře probádaná a věnuje se jí značné množství vědeckých publikací, zůstává pro veřejnost relativně uzavřená. Existuje jen velmi málo veřejně dostupných nástrojů. Komunita odborníků, jež se hyperspektrálními daty zabývá, si své objevy chrání a neposkytuje je k dalšímu výzkumu. Další nesnází je špatná optimalizace programu MATLAB pro zpracovávání trojrozměrných obrazových dat a práce na více jádrových procesorech. První zmíněný fakt je způsoben tím, že vyžaduje trojrozměrné matice ve formátu double (64 bit), ačkoliv by pro zkoumaná data bylo 16bitové vyjádření dostačující. Důsledkem toho docházelo ke zbytečnému vytížení operační paměti, protože některé kompresní metody vyžadovaly vytvoření několika pomocných matic o velikosti vstupních dat, následkem čehož došlo pro větší rozměry k přetížení, havárii programu a přerušení výpočtu. Během analýzy pak program plně vytěžoval vždy pouze jedno jádro čtyřjádrového procesoru, ostatní byla prakticky netknutá. Zbytečně tedy využíval jen zhruba čtvrtinu reálného výkonu a pracoval s čtyřnásobným objemem dat, než bylo nutné. Zmíněné se dramaticky odrazilo v časové náročnosti zkoumaných metod.

Bylo dokázáno, že naprosto zásadní roli hraje úvodní analýza dat a vhodná volba oblasti zájmu. Lze tak dosáhnout obrovské úspory dat přímo na vstupu (bez zanesení chyb a zkreslení). Odstraněním irelevantních pásem vodní absorpce lze navíc dosáhnout větší míry korelace, data je tedy možné komprimovat mnohem efektivněji. Došlo k návrhu velkého množství funkcí pro program MATLAB s účelem načtení, analýzy, měření a komprese hyperspektrálních dat. Zároveň došlo k několika neúspěšným snahám o realizaci algoritmů, které většina literatury označuje za nejvíce vhodné (například SPIHT, 3D SPIHT a EZW), bylo ovšem možné využít jejich verze, jež jsou implementované v nástrojích programu MATLAB. Tyto algoritmy v prostředí MATLAB bohužel nejsou uzpůsobené pro bezeztrátovou, ani téměř-bezeztrátovou kompresi. Navzdory tomu je bylo možné efektivně využít pro porovnání navržených bezeztrátových transformačních metody v závislosti na tom, jak vysoké PSNR a kompresní poměry přináší neboli jak efektivně připravují data pro následnou kompresi. Výsledky se velmi různily. Nejmenší ztrátovosti dosahovala metoda 2D PCA (PSNR až 57 dB, v kombinaci s 1D KLT pak téměř 59 dB). Největších kompresních poměrů dosahovala 3D DWT (téměř 72:1), 2D PCA (68:1, resp. 76:1 v kombinaci s 1D KLT) a absolutně největších kompresních poměrů dosahovala metoda 2D KLT (téměř 95:1, resp. 102:1 v kombinaci s 1D KLT. Velmi nečekaným faktem bylo to, že kombinace 1D KLT a 2D PCA měla za následek značné urychlení výpočtu (až o 29%) oproti samotné 2D PCA a to za současného zvýšení kompresního poměru i PSNR.

Další vývoj hyperspektrálních dat se zřejmě vyvaruje přidávání spektrálních kanálů, jejich počet je již v tuto chvíli dostačující, spíše bude docházet k lepšímu využití narůstajícího výpočetního výkonu. Bude docházet ke kvalitnějšímu pořizování dat (méně irelevantních oblastí), selekci oblastí bez oblačnosti a dalších nežádoucích jevů. Dále můžeme očekávat vhodnější aplikaci komprimovaného snímání, tj. kompresi již ve snímajícím zařízení. Větší využití lze také očekávat v oblasti 3D kompresních algoritmů, které jsou sice i v dnešní době výpočetně velmi náročné, avšak vhodná optimalizace, vyšší výpočetní výkon a snižující se spotřeba energie využijí jejich plného potenciálu. Vývoj se bude týkat i samotných snímacích zařízení, narůstající obliba dronů u rozšířila hyperspektrální zobrazování i do této oblasti – akvizice může probíhat z bezprostřední blízkosti i z výšky mnoha desítek metrů. Dochází tak ke snížení nákladů za pořízení obrazových dat a rozšíření do dalších vědních i průmyslových oborů.

## Literatura

- [1] „Electromagnetic radiation | physics", *Encyclopedia Britannica*. [Online]. Dostupné z: <https://www.britannica.com/science/electromagnetic-radiation>. [Viděno: 02-dub-2018].
- [2] P. Signell, „Electromagnetic Waves From Maxwell's Equations". Michigan State University.
- [3] M. K. Mandal, *Multimedia signals and systems*. Boston: Kluwer Academic Publishers, 2003.
- [4] D. R. Bull, „The Human Visual System", in *Communicating Pictures*, Elsevier, 2014, s. 17–61.
- [5] G. Motta, F. Rizzo, a J. A. Storer, Ed., *Hyperspectral data compression*. New York: Springer Science+Business Media, 2006.
- [6] „Radiance vs. Reflectance", *Harris Geospatial Solutions*. [Online]. Dostupné z: <https://www.harrisgeospatial.com/Support/Self-Help-Tools/Help-Articles/Help-Articles-Detail/ArtMID/10220/ArticleID/19247/3377>. [Viděno: 16-pro-2018].
- [7] P. Geladi a H. Grahn, *Multivariate image analysis*. Chichester ; New York: Wiley, 1996.
- [8] H. Grahn a P. Geladi, Ed., *Techniques and applications of hyperspectral image analysis*. Chichester, England ; Hoboken, NJ: J. Wiley, 2007.
- [9] D. H. Foster, „Tutorial on Transforming Hyperspectral Images to RGB Colour Images". 2018.
- [10] A. K. Singh, H. V. Kumar, G. R. Kadambi, J. K. Kishore, J. Shuttleworth, a J. Manikandan, „Quality Metrics Evaluation of Hyperspectral Images", *ISPRS - Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, roč. XL–8, s. 1221–1226, lis. 2014.
- [11] „NASA - AVIRIS for Dummies.pdf". [Online]. Dostupné z: [https://aviris.jpl.nasa.gov/links/AVIRIS\\_for\\_Dummies.pdf](https://aviris.jpl.nasa.gov/links/AVIRIS_for_Dummies.pdf). [Viděno: 04-pro-2018].
- [12] R. MicroImages Inc., „Analyzing Hyperspectral Images". .
- [13] C. Segal a S. Carman, „Hyperion Science Data User Guide", s. 60.
- [14] „AVIRIS - Airborne Visible / Infrared Imaging Spectrometer". [Online]. Dostupné z: <https://aviris.jpl.nasa.gov/>. [Viděno: 12-pro-2018].
- [15] E. Christophe, „Hyperspectral Data Compression Tradeoff", in *Optical Remote Sensing*, S. Prasad, L. M. Bruce, a J. Chanussot, Ed. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011, s. 9–29.
- [16] „Numeric Types - MATLAB & Simulink". [Online]. Dostupné z: <https://www.mathworks.com/help/matlab/numeric-types.html>. [Viděno: 17-pro-2018].
- [17] A. Said a W. A. Pearlman, „A new, fast, and efficient image codec based on set partitioning in hierarchical trees", *IEEE Trans. Circuits Syst. Video Technol.*, roč. 6, č. 3, s. 243–250, čer. 1996.
- [18] „Hyperspectral Remote Sensing Scenes - Grupo de Inteligencia Computacional (GIC)". [Online]. Dostupné z: [http://www.ehu.es/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes). [Viděno: 03-lis-2018].
- [19] „USGS.gov | Science for a changing world". [Online]. Dostupné z: <https://www.usgs.gov/>. [Viděno: 12-pro-2018].
- [20] E. Torrecilla, I. F. Aymerich, S. Pons, a J. Piera, „Effect of spectral resolution in hyperspectral data analysis", in *2007 IEEE International Geoscience and Remote Sensing Symposium*, Barcelona, Spain, 2007, s. 910–913.

- [21] A. M. M. Faisal Ghazi Mohamed Loay E. George, „Lossy Compression for Raw Satellite Images Using Intra Frame and Inter Frame Coding“, *Int. J. Sci. Res. IJSR*, roč. 6, č. 12, s. 425–432, pro. 2017.
- [22] S. Maji a A. Nath, „Scope and Issues in Alpha Compositing Technology“, *Int. J. Innov. Res. Adv. Eng.*, roč. 2, č. 12, s. 7, 2015.
- [23] E. Matouskova, K. Pavelka, a Z. Svadlenkova, „NON-INVASIVE SURVEY OF OLD PAINTINGS USING VNIR HYPERSPECTRAL SENSOR“, *ISPRS - Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, roč. XL-5/W2, s. 425–429, čvc. 2013.
- [24] E. Matoušková *et al.*, „USING REMOTELY SENSED DATA FOR DOCUMENTATION OF ARCHAEOLOGICAL SITES IN NORTHEASTERN MESOPOTAMIA“, *ISPRS - Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, roč. XLI-B5, s. 335–342, čer. 2016.
- [25] K. Pavelka, J. Šedina, E. Matoušková, M. Faltýnová, a I. Hlaváčová, „USING REMOTE SENSING AND RPAS FOR ARCHAEOLOGY AND MONITORING IN WESTERN GREENLAND“, *ISPRS - Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, roč. XLI-B1, s. 979–983, čer. 2016.
- [26] „Spectroscopy“, *Wikipedia*. 04-říj-2018.
- [27] M. I. Mladenov, E. . Dimitrov, M. P. Dejanov, a S. M. Penchev, „Hyperspectral Imaging System Based On Point Scan Spectrophotometer“. University of Ruse, 2015.
- [28] S. C. Yoon, B. Park, K. C. Lawrence, W. R. Windham, a G. W. Heitschmidt, „Line-scan hyperspectral imaging system for real-time inspection of poultry carcasses with fecal material and ingesta“, *Comput. Electron. Agric.*, roč. 79, č. 2, s. 159–168, lis. 2011.
- [29] M. S. Kim *et al.*, „Line-Scan Hyperspectral Imaging Platform for Agro-Food Safety and Quality Evaluation: System Enhancement and Characterization“, *Trans. ASABE*, roč. 54, č. 2, s. 703–711, 2011.
- [30] „AVIRIS - Airborne Visible / Infrared Imaging Spectrometer - Instrument“. [Online]. Dostupné z: <https://aviris.jpl.nasa.gov/aviris/instrument.html>. [Viděno: 05-pro-2018].
- [31] P. Ready a P. Wintz, „Information Extraction, SNR Improvement, and Data Compression in Multispectral Imagery“, *IEEE Trans. Commun.*, roč. 21, č. 10, s. 1123–1131, říj. 1973.
- [32] J. Pearlman *et al.*, „The EO-1 Hyperion Imaging Spectrometer“, s. 47.
- [33] B. U. Toreyin, O. Yilmaz, Y. M. Mert, a F. Turk, „Lossless hyperspectral image compression using wavelet transform based spectral decorrelation“, in *2015 7th International Conference on Recent Advances in Space Technologies (RAST)*, Istanbul, Turkey, 2015, s. 251–254.
- [34] Y. Hou, L. Liu, L. Yang, a X. Kang, „Hyperspectral Image Zeroblock Coding Algorithm Based on 3D KLT and Wavelet Transform“, in *2010 Chinese Conference on Pattern Recognition (CCPR)*, Chongqing, China, 2010, s. 1–5.
- [35] D. Báscones, C. González, a D. Mozos, „Hyperspectral Image Compression Using Vector Quantization, PCA and JPEG2000“, *Remote Sens.*, roč. 10, č. 6, s. 907, čer. 2018.
- [36] A. Tharwat, „Principal component analysis - a tutorial“, *Int. J. Appl. Pattern Recognit.*, roč. 3, č. 3, s. 197, 2016.
- [37] „PCA (Principal Component Analysis) - File Exchange - MATLAB Central“. [Online]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/30792>. [Viděno: 09-pro-2018].
- [38] „Wavelet Toolbox“. [Online]. Dostupné z: <https://www.mathworks.com/products/wavelet.html>. [Viděno: 13-říj-2018].

- [39]N. R. Mat Noor a T. Vladimirova, „Parallelised fault-tolerant Integer KLT implementation for lossless hyperspectral image compression on board satellites", in *2013 NASA/ESA Conference on Adaptive Hardware and Systems (AHS-2013)*, Torino, Italy, 2013, s. 115–122.
- [40]C. Egho a T. Vladimirova, „Adaptive hyperspectral image compression using the KLT and integer KLT algorithms", in *2014 NASA/ESA Conference on Adaptive Hardware and Systems (AHS)*, Leicester, United Kingdom, 2014, s. 112–119.
- [41]P. Baizert, M. R. Pickering, a M. J. Ryan, „Compression of hyperspectral data by spatial/spectral discrete cosine transform", in *IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium (Cat. No.01CH37217)*, Sydney, NSW, Australia, 2001, roč. 4, s. 1859–1861.
- [42]„Numberphile", *Numberphile*. [Online]. Dostupné z: <https://www.numberphile.com/>. [Viděno: 19-pro-2018].
- [43]S. R. Tate, „Band ordering in lossless compression of multispectral images", *IEEE Trans. Comput.*, roč. 46, č. 4, s. 477–483, dub. 1997.
- [44]R. E. Roger a M. C. Cavenor, „Lossless compression of AVIRIS images", *IEEE Trans. Image Process.*, roč. 5, č. 5, s. 713–719, kvě. 1996.
- [45]J. Mielikainen a P. Toivanen, „Clustered dpcm for the lossless compression of hyperspectral images", *IEEE Trans. Geosci. Remote Sens.*, roč. 41, č. 12, s. 2943–2946, pro. 2003.
- [46]Xiaolin Wu a N. Memon, „Context-based lossless interband compression-extending CALIC", *IEEE Trans. Image Process.*, roč. 9, č. 6, s. 994–1001, čer. 2000.
- [47]D. Huffman, „A Method for the Construction of Minimum-Redundancy Codes", *Proc. IRE*, roč. 40, č. 9, s. 1098–1101, zář. 1952.
- [48]M. Nelson, „Data Compression With Arithmetic Coding", *Mark Nelson*, 19-říj-2014. [Online]. Dostupné z: <https://marknelson.us/posts/2014/10/19/data-compression-with-arithmetic-coding.html>. [Viděno: 19-pro-2018].
- [49]Welch, „A Technique for High-Performance Data Compression", *Computer*, roč. 17, č. 6, s. 8–19, čer. 1984.
- [50]A. T. Murgan a R. Radescu, „A comparison of algorithms for lossless data compression using the Lempel-Ziv-Welch type methods", in *Proceedings of 1994 Workshop on Information Theory and Statistics*, Alexandria, VA, USA, 1994, s. 105.
- [51]U. Pratap a R. K. Sunkaria, „ECG compression using Compressed Sensing with Lempel-Ziv-Welch Technique", in *2015 1st International Conference on Next Generation Computing Technologies (NGCT)*, Dehradun, India, 2015, s. 863–867.
- [52]E. Christophe, P. Duhamel, a C. Mailhes, „Adaptation of Zerotrees Using Signed Binary Digit Representations for 3D Image Coding", *EURASIP J. Image Video Process.*, roč. 2007, s. 1–7, 2007.
- [53]J. M. Shapiro, „Embedded Image Coding Using Zerotrees of Wavelet Coefficients", s. 18.
- [54]K. Tarun a C. Deepak, „Compression Study Between ‘ezw’, spiht, stw, wdr, aswdr and spiht\_3d", roč. 4, č. 10, s. 6, 2013.
- [55]G. Motta, F. Rizzo, a J. A. Storer, „Compression of hyperspectral imagery", in *Data Compression Conference, 2003. Proceedings. DCC 2003*, Snowbird, UT, USA, 2003, s. 333–342.
- [56]M. J. Ryan a J. F. Arnold, „Lossy compression of hyperspectral data using vector quantization", *Remote Sens. Environ.*, roč. 61, č. 3, s. 419–436, zář. 1997.

- [57] R. Kieser, P. Reynisson, a T. Mulligan, „Definition of signal-to-noise ratio and its critical role in split-beam measurements", *ICES J. Mar. Sci.*, roč. 62, č. 1, s. 123–130, úno. 2005.
- [58] „Shannon–Hartley theorem", *Wikipedia*. 10-led-2018.
- [59] „Chybovost při přenosu digitálního signálu. Jiří Vodrážka - PDF". [Online]. Dostupné z: <http://docplayer.cz/41843379-Chybovost-pri-prenosu-digitalniho-signalu-jiri-vodrazka.html>. [Viděno: 13-bře-2018].
- [60] Zhou Wang a A. C. Bovik, „Mean squared error: Love it or leave it? A new look at Signal Fidelity Measures", *IEEE Signal Process. Mag.*, roč. 26, č. 1, s. 98–117, led. 2009.
- [61] Emack, „Image and Video quality assessment – Part One: MSE & PSNR | Emanuele Colucci Personal Home". .
- [62] „Measures of image quality". [Online]. Dostupné z: [http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL\\_COPIES/VELDHUIZEN/node18.html](http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/VELDHUIZEN/node18.html). [Viděno: 13-bře-2018].
- [63] A. Ahmed, „Analysis of Inter-band Spectral Cross-Correlation Structure of Hyperspectral Data", s. 8.
- [64] „AVIRIS Data Portal". [Online]. Dostupné z: [https://aviris.jpl.nasa.gov/alt\\_locator/](https://aviris.jpl.nasa.gov/alt_locator/). [Viděno: 31-říj-2018].
- [65] „Landsat8 Data Explorer - File Exchange - MATLAB Central". [Online]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/49907>. [Viděno: 31-říj-2018].
- [66] „Cloud Object Storage | Store & Retrieve Data Anywhere | Amazon Simple Storage Service", *Amazon Web Services, Inc.* [Online]. Dostupné z: <https://aws.amazon.com/s3/>. [Viděno: 31-říj-2018].
- [67] „LC80630462017074LGN00". [Online]. Dostupné z: <https://s3-us-west-2.amazonaws.com/landsat-pds/L8/063/046/LC80630462017074LGN00/index.html>. [Viděno: 31-říj-2018].
- [68] „EO-1 General Mission". [Online]. Dostupné z: <https://eo1.gsfc.nasa.gov/new/general/>. [Viděno: 19-pro-2018].
- [69] esa, „Sentinel ESA", *European Space Agency*. [Online]. Dostupné z: [https://www.esa.int/Our\\_Activities/Observing\\_the\\_Earth/Copernicus/Overview4](https://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview4). [Viděno: 19-pro-2018].
- [70] „Maui", *Wikipedia*. 02-pro-2018.
- [71] J. E. Fowler, „Hyperspectral Image Compression Using JPEG2000 and Principal Component Analysis". [Online]. Dostupné z: <http://my.ece.msstate.edu/faculty/fowler/Publications/DF2007.html>. [Viděno: 19-pro-2018].
- [72] A. Zemliachenko, V. Lukin, a B. Vozel, „Lossy compression of hyperspectral images based on JPEG2000", in *2017 4th International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T)*, Kharkov, 2017, s. 600–603.
- [73] „Multidimensional Discrete Cosine Transform (DCT) - File Exchange - MATLAB Central". [Online]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/24050>. [Viděno: 09-pro-2018].
- [74] „DCT - File Exchange - MATLAB Central". [Online]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/57611>. [Viděno: 10-pro-2018].
- [75] „KL Transform (Karhunen–Loève Theorem) - File Exchange - MATLAB Central". [Online]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/37082>. [Viděno: 05-led-2019].

- [76] „Wavelet Data Compression - MATLAB & Simulink“. [Online]. Dostupné z: <https://www.mathworks.com/help/wavelet/ug/wavelet-data-compression.html>. [Viděno: 02-led-2019].
- [77] „True compression of images using wavelets - MATLAB wcompress“. [Online]. Dostupné z: <https://www.mathworks.com/help/wavelet/ref/wcompress.html>. [Viděno: 02-led-2019].

## Příloha A – DVD 1

Jméno složky	Popis
aviris_data	Zdrojová data Aviris
hyperion_data	Zdrojová data Hyperion
KSC_data	Zdrojová data KSC
landsat8_data	Zdrojová data Landsat 8
sentinel2_data	Zdrojová data Sentinel 2

## Příloha B – DVD 2

Jméno složky	Popis
DWT	Kompletní výsledky testování metod 1D, 2D a 3D DWT (časová náročnost pro všechny úrovně i typy vlnek)
MATLAB	Obsahuje hlavní skript <code>Komprese_hyperspektranich_dat.m</code>
Naměřené parametry	Kompletní výsledky pro všechny navržené metody komprese (PSNR, bpp, kompresní poměr, doba komprese)
TNTmips	Hyperkrychle vytvořené v programu TNTmips
Zpracovaná data pro Matlab	Veškerá testovaná data ve formátu .mat





