

**Technická zpráva
o snímání, aplikacích a knihovnách pro
zpracování multispektrálního obrazu**

Technická zpráva M2_TH03010330

J. Schier

Praha, 2019

Tento dokument byl vytvořen s finanční podporou TA ČR v rámci výzkumného programu TH03010330 (BOREC – Barevný Obraz v prostředí „Realtime Embedded Computing“).

Číslo a název projektu

TH03010330

BOREC – Barevný Obraz v prostředí „Realtime Embedded Computing“

Název a popis dílčího výsledku

Průběžná technická zpráva o snímání a vlastnostech barevného/multispektrálního obrazu

Technická zpráva shrnující výzkum postupů, zejména analýzu snímacích zařízení, experimentů multispektrální analýzy, extrakci příznaků, detekci objektů atd.

Jazyk dokumentu

Čeština

Organizace a řešitel

Ústav teorie informace a automatizace AV ČR, v.v.i.

Dr. Ing. Jan Schier

Anotace

V práci je prezentována stručná rešerše metod pořízení multispektrálního a hyperspektrálního obrazu, aplikací hyperspektrálního snímkování a základních metod jeho zpracování. V závěru práce je podán přehled nalezených knihoven pro zpracování hyperspektrálního obrazu v jazycích Matlab a Python.

Klíčová slova

Hyperspektrální snímkování, aplikace hyperspektrálního obrazu, knihovny pro zpracování hyperspektrálního obrazu

Abstract

This report presents brief overview of multispectral and hyperspectral image acquisition methods, of applications of hyperspectral imaging and of basic methods of hyperspectral image processing. In the final part, we present an overview of Matlab and Python software libraries for hyperspectral image processing.

Keywords

Hyperspectral imaging, hyperspectral imaging applications, software libraries for hyperspectral image processing


Obsah

1	Princip hyperspektrální reprezentace snímku	1
1.1	Snímání hyperspektrálního obrazu	1
2	Aplikace multispektrálního a hyperspektrálního snímkování	2
3	Specifika multispektrálního snímkování	3
4	Vybrané metody	4
4.1	Shluková analýza a redukce dimenzionality	4
4.2	Zvyšování rozlišení hyperspektrálních snímků	5
4.3	Mapování chromaticity	5
4.4	Metody, založené na použití konvolučních sítí	6
5	Implementace	7
5.1	Knihovny pro zpracování multispektrálního a hyperspektrálního obrazu	7
6	Závěr	8
7	Odkazy	8

1 Princip hyperspektrální reprezentace snímku

Obvyklý způsob barevného zobrazení je pomocí tří barevných složek: červené, zelené a modré. Ty přibližně odpovídají barevné citlivosti čípků (barevně citlivých světločivných buněk) v lidském oku.


Naproti tomu, při hyperspektrálním snímkování se pro každý pixel snímku zaznamenává jeho plné spektrum, výsledná data tedy pro dvourozměrný obraz tvoří tzv. datovou kostku, kde třetí rozměr snímku reprezentuje vlnovou délku světla (viz Obrázek 1) – viz např. Hagen a Kudenov (2013).



Obrázek 1 – Datová kostka multispektrálního obrazu

1.1 Snímání hyperspektrálního obrazu

Pro záznam hyperspektrálního obrazu se používá řada technologických řešení. Ta se musí vypořádat s omezeními danými jednak nutností řešit spektrální rozklad světla, ať už použitím rozkladného hranolu, difrakční mřížky, nebo jednotlivých filtrů, jednak nutností použít řádkový nebo maticový senzor. Obraz je nutné pořizovat po částech – viz Obrázek 2.



Obrázek 2 – Různé způsoby pořízení hyperspektrálního obrazu

Velmi dobrý přehled snímacích konfigurací lze najít v Hagen a Kudenov (2013). Práce dělí systémy na dvě velké skupiny: skenovací spektrometrické systémy (např. s pohybem rozkladného hranolu nebo s laděným spektrálním

filtrem, obecně s postupnou expozicí) a snapshot systémy (používající záznam spektra během jedné expozice). Do druhé skupiny patří např. systémy s rozdělováním paprsku (beamsplitter systems). Častou nevýhodou těchto systémů je omezený počet spektrálních pásem, daný technickými omezeními počtu splitterů a spektrálních filtrů.

2 Aplikace multispektrálního a hyperspektrálního snímkování

Tradiční aplikační oblastí multispektrálního a hyperspektrálního byla oblast leteckého a družicového snímkování země. Jedna z prvních zmínek byla publikována v práci „Imaging Spectrometry for Remote Sensing“ – viz Goetz et al. (1985). Jde o přehledový článek, zachycující stav snímacích systémů a zpracování multispektrálního obrazu v roce 1985. Práce zmiňuje různé konfigurace senzorů pro multispektrální snímkování (senzor s diskrétními detektory, multispektrální snímkování s řádkovým detektorem, obrazovou spektrometrii s plošným polem), je v ní také zmíněn vývoj leteckého systému hyperspektrálního snímkování AVIRIS, systém Landsat, a popsány některé praktické aplikace v dané době.

Zajímavým dokladem o vývoji v oblasti je Tong, Xue a Zhang (2014), který shrnuje třicet let vývoje technologie hyperspektrálního vzdáleného průzkumu v Číně.

V současné době se multispektrální snímkování používá kromě dálkového průzkumu i v řadě dalších oblastí. Ty zahrnují např. kontrolu kvality potravin: v práci Liu, Zeng a Sun (2013) je popsáno použití NIR spektroskopie pro kontrolu výskytů parazitů, zbytků krve a dalších nežádoucích složek v rybím mase. V práci je zmíněn systém, používající vláknovou optiku, s pracovním pásmem 800–1089 nm a systém s LED polem v pásmu 900–1700 nm. NIR pásmo bylo použito pro hodnocení obsahu tuku v mase a pro hodnocení čerstvosti masa. Údaje jsou shrnuty v následující tabulce:

Složka	Absorbent	Vlnová délka (nm)
voda	–OH	1920–1950, 1400–1450
Bílkoviny	–NH	2080–2220, 1560–1670
Tuky	–CH	2300–2350
	–CH ₂ , –CH ₃	1680–1760
Sacharidy	C-O, O-H	2060–2150

Caporaso, Whitworth a Fisk (2018) obsahuje rozsáhlé shrnutí použití NIR spektroskopie a hyperspektrálního snímkování pro hodnocení kvality obilovin, konkrétně pro hodnocení klíčovosti a aktivity α -amylázy (enzym, ovlivňující kvalitu sladování). Systémy, uváděné v přehledu tohoto článku, používají pásmo 1225–2300 nm. Pro hodnocení aktivity α -amylázy postačovalo 6 vlnových délek, při použití celého spektra bylo dosahováno lepší predikce.

NIR spektroskopie byla úspěšně použita také ve farmaceutickém průmyslu: Baptistao, Rocha a Poppi (2011) popisuje použití pro kontrolu kvality tablet paracetamolu, Lyon et al. (2002) použití NIR systému MatrixNIR (Spectral Dimensions, Inc., Olney, MD) pro kontrolu homogenity směsi v lékových tabletách.

Řadu aplikací lze najít také v analýze starých uměleckých děl, např. rukopisů: práce Wijnsman et al. (2018) popisuje průzkum pigmentů, použitých na středověkých hebrejských rukopisech. Ke snímkování je zde použit VIS–NIR systém, obsahující sadu filtrů s propustností od 400 do 800 nm, s odstupňováním po 50 nm a filtr na 880 nm. Další příklady obsahují analýzu materiálů a technik, používaných v iluminovaných rukopisech z 15. století (Ricciardi et al. (2013)), analýzu poškozených fragmentů svitků papyru z Herkulanea, Petry a Judské pouště (Chabries, Booras a Bearman (2003)), skenování malířských děl s vysoce přesným barevným rozlišením, atd. V práci Walvoord a Easton (2008) je popsána analýza skrytého Archimédova rukopisu (palimpsestu). O použitém snímkovacím systému je uvedeno pouze, že používá UV osvětlení na vlnové délce $\lambda = 365$ nm a žárovkové osvětlení, filtrované v R, G, B a dvou IR pásmech, celkem tedy 6 různých spektrálních pásem.

Práce Liang (2012) obsahuje poměrně obsáhlé shrnutí problematiky systémů pro snímkování uměleckých děl. V této práci jsou uvedeny požadavky na snímací zařízení a techniky snímkování v oblasti muzeálního snímkování, problematika kalibrace zařízení a zdroje chyb, registrace obrazu (nutná při použití některých konfigurací). Stojí za zmínku, že např. pro vystavování starých rukopisů je, s ohledem na riziko jejich poškození, požadovaná úroveň osvětlení pouhých 50 luxů, při snímkování historických materiálů existuje limit celkové absorbované energie, kdy ještě nedojde k poškození pigmentů.

V práci jsou zmíněny moderní *elektronicky laditelné filtry*: Liquid Crystal Tunable Filter (LCTF) a Acousto-Optical Tunable Filters (AOTF). Výhodou těchto filtrů je absence pohyblivých částí (které zásadně zpomalují přepínání filtrů), *rychlá přeladitelnost* a možnost *naladění libovolné centrální vlnové délky*.

Rychlost ladění LCTF je dána relaxační dobou krystalu a je v řádu desítek až stovek milisekund. Filtry mají pevně dané pásmo, svázané s centrální vlnovou délkou. Podle Liang (2012) byly v oblasti průzkumu uměleckých děl používány vlnové délky 400–700 nm, resp. 650–1040 nm, AOTF filtry umožňují ladění v rozsahu 350–5000 nm.

Při pořizování snímků je možné filtrovat buď zdroj osvětlení, nebo odražené světlo. První způsob přináší menší zatížení snímkaného artefaktu a možnost použít jednoduché kamery, ale s ohledem na příspěvek osvětlení pozadí je to technika použitelná pouze ve studiu. Při výběru vlnové délky odraženého světla je možné buď zaznamenat plné spektrum jednoho bodu a snímek postupně skenovat, nebo zaznamenat celý snímek postupně na různých vlnových délkách.

3 Specifika multispektrálního snímkování

Multispektrální a hyperspektrální snímkování s sebou nese některá specifika, se kterými se nesetkáváme při zpracování obvyklých barevných snímků:

- informační obsah snímků na blízkých vlnových délkách je podobný, z toho vyplývá „řídkost“ (sparsity) dat a potřeba jejich komprese.
- hrubší vzorkování obrazu (větší pixely) při použití některých konfigurací optické soustavy, dané mechanickým pohybem optických prvků, použitých pro rozklad spektra
- nižší odstup signálu od šumu, daný útlumem signálu při průchodu přes rozkladné optické prvky (optické filtry, rozkladné hranoly, apod.)
- vysoký objem dat v jednom snímku, daný desítkami až stovkami spektrálních pásem (podle konkrétní technologie pořízení snímků). Ten vyvolává nutnost určit signálový podprostor (*signal subspace identification*), aby se s daty dalo efektivně nakládat.
- *segmentace* obrazu: obvykle používané segmentační metody předpokládají šedotónový obraz (grayscale image), a řeší např. nespojitost hranice objektů nebo segmentaci obrazu podle obsažených textur. Pro segmentaci multispektrálního obrazu je třeba použít shlukovací metody.
- mapování obrazu do RGB prostoru: potřebné pro případnou vizualizaci barevného obrazu.

4 Vybrané metody

4.1 Shluková analýza a redukce dimenzionality

V případě segmentace barevného obrazu ve formátu RGB se často používá jeho transformace do prostoru HSV nebo CIE L*a*b, která umožňuje transformaci úlohy segmentace podle barvy opět na transformaci šedotónového obrazu. V případě multispektrálního nebo hyperspektrálního obrazu se používají metody shlukové analýzy (cluster analysis), které umožňují zohlednit spektrální informaci obsaženou v každém pixelu.

Problematikou použití technik shlukové analýzy v analýze multispektrálního, resp. hyperspektrálního obrazu se zabývá např. Danielle Nuzillard a Lazar (2007), která obsahuje rozsáhlý přehled různých technik. Tato práce se věnuje technikám redukce dimenze obrazu (Independent Component Analysis (ICA), Principal Component Analysis (PCA), Karhunen-Loeve transformace, a faktorové analýzy). Spektra v jednotlivých pixelech obrazu jsou chápána jako vektory. Autoři zavádějí tzv. magnitude-shape representation, s jejíž pomocí pak hodnotí podobnost těchto vektorů na základě jejich směru a velikosti. Při tom používají parametr Spectral Angle, definovaný jako

$$SA = \arccos \frac{A^T B}{\|A\| \|B\|}$$

a korelační koeficient

$$r = \frac{\sum_{i=1}^d (A_i - \mu_A)(B_i - \mu_B)}{(d-1)\sigma_A\sigma_B}$$

Závěr práce je věnován divizivním shlukovacím metodám (partitional clustering): Parzen-watershed algoritmu a suport-vector clusteringu

Bijaoui, Nuzillard a Barma (2004) pojednává příbuznost mezi metodami Blind source separation a shlukové analýzy. Zajímavá je poznámka o použití metod slepé separace při analýze snímků z Hubblova teleskopu.

Velmi rozsáhlý přehled metod pro redukcí dimenzionality a spectral unmixing, zaměřený na hyperspektrální data, je prezentovaný v Veganzones a Graña (2012). Tato práce obsahuje téměř 80 referencí.

V práci Sarhrouni, Hammouch a Aboutajdine (2012) je problém redukcí dimenzionality a klasifikace řešen pomocí vzájemné informace (mutual information) a symetrické nejistoty (symmetric uncertainty). Metody jsou aplikovány na hyperspektrální testovací snímek „Indiana Pines“, pořízený systémem AVIRIS.

Arsene et al. (2015) popisuje výsledky použití osmi metod pro redukcí dimenze: Generalized Discriminant Analysis (GDA), Linear Discriminant Analysis (LDA), Neighborhood Component Analysis (NCA), Gaussian Process Latent Variable Model (GPLVM), Isomap, Landmark Isomap, Principal Component Analysis (PCA) a Probabilistic Principal Component Analysis (PPCA) při analýze starých rukopisů.

Zajímavý přístup pro spectral unmixing byl prezentován v Xu et al. (2018): metoda Linear Iterative Clustering (SLIC) používá místní prohledávání se zahrnutím prostorových korelací a hodnocení podobnosti spektra do procedury shlukování, při čemž dosahuje výpočetní složitosti $\mathcal{O}(N)$. I tato práce obsahuje rozsáhlý přehled metod v oblasti shlukování a spectral unmixing pro hyperspektrální snímky.

4.2 Zvyšování rozlišení hyperspektrálních snímků

Omezené rozlišení hyperspektrálního obrazu je zajímavým způsobem řešeno v Kawakami et al. (2011): navrhovaná metoda používá kombinaci RGB snímku s vysokým rozlišením a hyperspektrálního snímku s nižším rozlišením (u testovacích příkladu bylo použito rozlišení RGB snímku 512×512 pixelů, rozlišení hyperspektrálního snímku bylo podvzorkováním sníženo na 16×16 pixelů). Metoda je založena na spectral unmixing rozkladu hyperspektrálního snímku, formulovaném jako faktorizace řídké matice a řešení pomocí ℓ^1 minimalizace. Báze, která je výsledkem řešení faktorizace, je použita spolu s RGB obrazem pro rekonstrukci spektra v jednotlivých bodech snímku.

4.3 Mapování chromaticity

Problém mapování multispektrálního snímku pro jeho zobrazení je zajímavým způsobem řešen např. v Lan et al. (2013). V této práci je prezentována metoda pro interaktivní lokální nastavení mapování barevné tonality. Metoda je založena na faktorizaci multispektrálního obrazu na dvě složky: jednu, která reprezentuje prostorovou koherenci mezi pixely, druhou, která popisuje spektrální koherenci mezi různými vlnovými délkami. Interaktivní vstup je proveden tahy

„štetce“ ve snímku, metoda následně propaguje hodnoty z těchto stop do zbytku snímku.

Problém optimalizace (a minimalizace) spektrálních pásem, nutných pro pořízení obrazu dané scény, je řešen v Li et al. (2018): typický způsob pořízení multispektrálního snímku je buď vícenásobnou expozicí za použití několika různých filtrů, nebo jednou expozicí s použitím mozaiky filtrů. Při použití vícenásobné expozice se používá řada úzkopásových filtrů, což však podstatně prodlužuje dobu pořízení snímku, nebo rolišení snímku při použití mozaikových filtrů. Kromě toho, použití úzkopásových filtrů podstatně snižuje množství světla, které projde na senzor, což vede k obtížným expozičním

podmínkám. Cílem práce Li et al. (2018) je optimalizovat použití filtrů se širším pásmem pomocí optimalizované volby použitých pásem. Za tím účelem používá kritérium, sestavené z rekonstrukční chyby, míry šumu a chyby potlačení mozaiky (demosaijing error). Tento problém je obdobný jednomu z cílů našeho projektu, kterým je vyhledávání v databázi světelných zdrojů a filtrů pro snímání dané scény.

4.4 Metody, založené na použití konvolučních sítí

V posledních letech proniká do všech oblastí zpracování obrazu použití konvolučních neuronových sítí. Výjimkou není, samozřejmě, ani zpracování hyperspektrálního obrazu.

Jako příklady prací, zaměřených tímto směrem, lze uvést klasifikaci hyperspektrálního obrazu pomocí hluboké konvoluční sítě v Hu et al. (2015) a v novější práci Gao, Lim a Jia (2018). V obou těchto pracech je řešena klasická úloha klasifikace snímku z dálkového průzkumu země. V první z nich je použita poměrně jednoduchá síť s jednou konvoluční a jednou sdružovací (poolovací) vrstvou, následovanou jednou plně propojenou a jednou výstupní vrstvou. Tato síť je porovnávána s klasifikátorem, založeným na RBF-SVM.

Gao, Lim a Jia (2018) používá takzvané profily atributů (Attribute Profiles), které umožňují zachytit několik morfologických profilů. Každý z těchto profilů atributů je vyhodnocován samostatnou konvoluční sítí. Výsledné profily jsou spojeny do jedné slučující vrstvy a hodnoceny v klasifikátoru, složeném z konvoluce a SoftMax výstupní vrstvy.

Jiný charakter úlohy je řešen v práci Nagasubramanian et al. (2018). V této práci je 3D konvoluční síť použita pro klasifikaci zdravých a infikovaných stonků sóji z hyperspektrálních dat. Pořízení hyperspektrálních snímků probíhalo v této práci v laboratorních podmínkách, k hodnocení byla použita síť se dvěma konvolučními a dvěma plně propojenými vrstvami.

5 Implementace

5.1 Knihovny pro zpracování multispektrálního a hyperspektrálního obrazu

Rešerší zdrojů, dostupných na Internetu, byly nalezeno několik volně dostupných knihoven pro zpracování hyperspektrálního obrazu. V rešerši jsme se zaměřili zejména na implementace v Matlabu a Pythonu:

MATLAB

[MATLAB Hyperspectral Toolbox](#)

Knihovna, dostupná na Matlab File Exchange, s poslední aktualizací v roce 2017, zaměřená na zpracování AVIRIS leteckých snímků.

Knihovna obsahuje funkce pro detekci cíle (target detection – úloha obdobná segmentační úloze – vyhledávají se pixely, obsahující požadované spektrum), pro vytváření tzv. abundance map (mapy poměrného zastoupení jednotlivých spekter), funkce pro spektrální unmixing, vizualizaci, atd.

V současné době není tato knihovna udržována.

[Semantic Segmentation of Multispectral Images Using Deep Learning](#)

V tomto případě nejde o knihovnu, ale o podrobně zpracovaný příklad v dokumentaci systému Matlab, ukazující semantickou segmentaci multispektrálního leteckého snímku pomocí U-net sítě.

[DAFNE: A Matlab Toolbox for Bayesian multi-source remote sensing and ancillary data fusion](#), viz D'Addabbo et al. (2018). Knihovna pro Bayesovské zpracování dat z více zdrojů a fúzi pomocných dat z dálkového průzkumu Země. Pracuje s daty ve formátu Matlabského pole (native Matlab array) a s binárními soubory ve formátu GeoTIFF (ty zajišťují kompatibilitu s jinými nástroji pro zpracování dat z dálkového průzkumu Země)

Python

[Spectral Python \(SPy\)](#)

Knihovna, zaměřená na práci s hyperspektrálními daty, s podporou ENVI datových souborů a ECOSTRESS knihovny. Knihovna má funkce pro zobrazení dat (RGB, spektrum, datový hypercube), klasifikaci, redukci dimenzionality, spektrální transformace, atd. Podle údajů na webových stránkách však vývoj této knihovny zřejmě v podstatě skončil v roce 2017.

[HyperSpy](#)

Knihovna pro práci s vícerozměrnými daty, zaměřená zejména na data z elektronové mikroskopie.

[PySptools: A hyperspectral imaging toolbox](#)

Rozsáhlá knihovna pro práci s multispektrálními a hyperspektrálními daty, obsahující funkce pro klasifikaci, detekci, endmembers extraction, machine learning, a další metody. Aktualizace v letech 2016-2018.

DeepHyperX

Toolbox pro klasifikaci hyperspektrálních snímků, založený na deep learning knihovně PyTorch. Obsahuje dvě metody, založené na SVM a 11 různých metod, založených zejména na konvolučních sítích Audebert, Le Saux a Lefevre (2019). Poslední vydání kódu bylo v roce 2018, poslední úpravy repository v roce 2019.

Z výše uvedeného přehledu je patrné zaměření knihoven zejména na dálkový průzkum Země. Většina knihoven je k dispozici pro jazyk Python. U řady nalezených knihoven pravděpodobně skončil aktivní vývoj.

<https://github.com/nshaud/DeepHyperXDeepHyperX>

6 Závěr

Dokument podává přehled existujících aplikací multispektrálního a hyperspektrálního snímkování, spolu s jejich požadavky na data.

Zároveň je zde provedena stručná rešerše metod, používaných v oblasti zpracování spektrálního obrazu, např. pro redukci dimenzionality, segmentaci obrazu, mapování chromacity, atd.

Jsou zmíněny některé již existující softwarové knihovny pro Matlab a Python. Většina těchto knihoven je zaměřena zejména na zpracování dat z dálkového průzkumu Země. Společným problémem části z nich je přerušovaný vývoj.

7 Odkazy

- Arsene, Corneliu T.C. et al. (2015). „Computational Techniques in Multispectral Image Processing: Application to the Syriac Galen Palimpsest Corneliu“. In: *Second International Conference on Natural Sciences and Technology in Manuscript Analysis*, s. 29–30 (cit. na s. 5).
- Audebert, Nicolas, Bertrand Le Saux a Sebastien Lefevre (2019). „Deep learning for classification of hyperspectral data: A comparative review“. In: *IEEE Geoscience and Remote Sensing Magazine* 7.2, s. 159–173. ISSN: 21686831. DOI: [10.1109/MGRS.2019.2912563](https://doi.org/10.1109/MGRS.2019.2912563). arXiv: [1904.10674](https://arxiv.org/abs/1904.10674) (cit. na s. 8).
- Baptistao, Mariana, Werickson Fortunato De Carvalho Rocha a Ronei Jesus Poppi (2011). „Quality control of the paracetamol drug by chemometrics and imaging spectroscopy in the near infrared region“. In: *Journal of Molecular Structure* 1002.1-3, s. 167–171. ISSN: 00222860. DOI: [10.1016/j.molstruc.2011.07.019](https://doi.org/10.1016/j.molstruc.2011.07.019). arXiv: [arXiv:1011.1669v3](https://arxiv.org/abs/1011.1669v3) (cit. na s. 3).
- Bijaoui, A, D Nuzillard a T D Barma (2004). „BSS, classification and pixel demixing“. In: *Independent Component Analysis and Blind Signal Separation* 3195.SEPTEMBER 2004, s. 97–104. ISSN: 03029743. DOI: [10.1007/978-3-540-30110-3](https://doi.org/10.1007/978-3-540-30110-3) (cit. na s. 5).
- Caporaso, Nicola, Martin B. Whitworth a Ian D. Fisk (2018). „Near-Infrared spectroscopy and hyperspectral imaging for non-destructive quality assessment of cereal grains“. In: *Applied Spectroscopy Reviews* 53.8, s. 667–687. ISSN: 1520569X. DOI: [10.1080/05704928.2018.1425214](https://doi.org/10.1080/05704928.2018.1425214) (cit. na s. 2).

- D'Addabbo, Annarita et al. (břez. 2018). „DAFNE: A Matlab toolbox for Bayesian multi-source remote sensing and ancillary data fusion, with application to flood mapping“. In: *Computers & Geosciences* 112, s. 64–75. ISSN: 0098-3004. DOI: [10.1016/J.CAGEO.2017.12.005](https://doi.org/10.1016/J.CAGEO.2017.12.005) (cit. na s. 7).
- Gao, Qishuo, Samsung Lim a Xiuping Jia (2018). „Hyperspectral image classification using convolutional neural networks and multiple feature learning“. In: *Remote Sensing* 10.2. ISSN: 20724292. DOI: [10.3390/rs10020299](https://doi.org/10.3390/rs10020299) (cit. na s. 6).
- Goetz, Alexander F.H. et al. (1985). „Imaging spectrometry for earth remote sensing“. In: *Science* 228.4704, s. 1147–1153. ISSN: 00368075. DOI: [10.1126/science.228.4704.1147](https://doi.org/10.1126/science.228.4704.1147) (cit. na s. 2).
- Hagen, Nathan a Michael W. Kudenov (zář. 2013). „Review of snapshot spectral imaging technologies“. In: *Optical Engineering* 52.9, s. 090901. ISSN: 0091-3286. DOI: [10.1117/1.OE.52.9.090901](https://doi.org/10.1117/1.OE.52.9.090901) (cit. na s. 1).
- Hu, Wei et al. (2015). „Deep Convolutional Neural Networks for Hyperspectral Image Classification“. In: *Journal of Sensors* 2015, s. 1–12. ISSN: 1687-725X. DOI: [10.1155/2015/258619](https://doi.org/10.1155/2015/258619) (cit. na s. 6).
- Chabries, Douglas M., Steven W. Booras a Gregory H. Bearman (červ. 2003). „Imaging the past: recent applications of multispectral imaging technology to deciphering manuscripts“. In: *Antiquity* 77.296, s. 359–372. ISSN: 0003-598X. DOI: [10.1017/S0003598X00092346](https://doi.org/10.1017/S0003598X00092346) (cit. na s. 3).
- Kawakami, Rei et al. (2011). „High-resolution hyperspectral imaging via matrix factorization“. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, s. 2329–2336. ISSN: 10636919. DOI: [10.1109/CVPR.2011.5995457](https://doi.org/10.1109/CVPR.2011.5995457) (cit. na s. 5).
- Lan, Yanxiang et al. (2013). „Interactive chromaticity mapping for multispectral images“. In: *User Modeling and User-Adapted Interaction* 29.6-8, s. 773–783. ISSN: 01782789. DOI: [10.1007/s00371-013-0829-x](https://doi.org/10.1007/s00371-013-0829-x) (cit. na s. 5).
- Li, Yuqi et al. (dub. 2018). „Optimized Multi-Spectral Filter Array Based Imaging of Natural Scenes“. In: *Sensors* 18.4, s. 1172. ISSN: 1424-8220. DOI: [10.3390/s18041172](https://doi.org/10.3390/s18041172) (cit. na s. 6).
- Liang, Haida (ún. 2012). „Advances in multispectral and hyperspectral imaging for archaeology and art conservation“. In: *Applied Physics A* 106.2, s. 309–323. ISSN: 0947-8396. DOI: [10.1007/s00339-011-6689-1](https://doi.org/10.1007/s00339-011-6689-1) (cit. na s. 3).
- Liu, Dan, Xin An Zeng a Da Wen Sun (2013). „NIR spectroscopy and imaging techniques for evaluation of fish quality - A review“. In: *Applied Spectroscopy Reviews* 48.8, s. 609–628. ISSN: 05704928. DOI: [10.1080/05704928.2013.775579](https://doi.org/10.1080/05704928.2013.775579) (cit. na s. 2).
- Lyon, Robbe C. et al. (2002). „Near-infrared spectral imaging for quality assurance of pharmaceutical products: Analysis of tablets to assess powder blend homogeneity“. In: *AAPS Pharm.Sci.Tech* 3.3. ISSN: 15309932. DOI: [10.1007/BF02830615](https://doi.org/10.1007/BF02830615) (cit. na s. 3).
- Nagasubramanian, Koushik et al. (2018). „Explaining hyperspectral imaging based plant disease identification: 3D CNN and saliency maps“. In: *Nips 2017*, s. 3–10. arXiv: [1804.08831](https://arxiv.org/abs/1804.08831) (cit. na s. 6).

- Nuzillard, Danielle a Cosmin Lazar (pros. 2007). „Partitional Clustering Techniques for Multi-Spectral Image Segmentation“. In: *Journal of Computers* 2.10, s. 1–8. ISSN: 1796-203X. DOI: [10.4304/jcp.2.10.1-8](https://doi.org/10.4304/jcp.2.10.1-8) (cit. na s. 4).
- Ricciardi, Paola et al. (ún. 2013). „Use of Imaging Spectroscopy and in situ Analytical Methods for the Characterization of the Materials and Techniques of 15th Century Illuminated Manuscripts“. In: *Journal of the American Institute for Conservation* 52.1, s. 13–29. ISSN: 0197-1360. DOI: [10.1179/0197136012Z.0000000004](https://doi.org/10.1179/0197136012Z.0000000004) (cit. na s. 3).
- Sarhrouni, Elkebir, Ahmed Hammouch a Driss Aboutajdine (2012). „Application of symmetric uncertainty and mutual information to dimensionality reduction and classification of hyperspectral images“. In: *International Journal of Engineering and Technology* 4.5, s. 268–276. ISSN: 09754024. DOI: [10.1007/s10014-013-0150-4](https://doi.org/10.1007/s10014-013-0150-4). arXiv: [1211.0613](https://arxiv.org/abs/1211.0613) (cit. na s. 5).
- Tong, Qingxi, Yongqi Xue a Lifu Zhang (2014). „Progress in hyperspectral remote sensing science and technology in China over the past three decades“. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7.1, s. 70–91. ISSN: 19391404. DOI: [10.1109/JSTARS.2013.2267204](https://doi.org/10.1109/JSTARS.2013.2267204) (cit. na s. 2).
- Veganzones, Miguel A. a Manuel Graña (2012). „Hybrid computational methods for hyperspectral image analysis“. In: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 7209 LNAIPART 2, s. 424–435. ISSN: 03029743. DOI: [10.1007/978-3-642-28931-6_41](https://doi.org/10.1007/978-3-642-28931-6_41) (cit. na s. 5).
- Walvoord, D.J. a R.L. Easton (čvc 2008). „Digital Transcription of the Archimedes Palimpsest [Applications Corner]“. In: *IEEE Signal Processing Magazine* 25.4, s. 100–104. ISSN: 1053-5888. DOI: [10.1109/MSP.2008.924960](https://doi.org/10.1109/MSP.2008.924960) (cit. na s. 3).
- Wijsman, Suzanne et al. (pros. 2018). „Uncovering the Oppenheimer Siddur: using scientific analysis to reveal the production process of a medieval illuminated Hebrew manuscript“. In: *Heritage Science* 6.1, s. 15. ISSN: 2050-7445. DOI: [10.1186/s40494-018-0179-0](https://doi.org/10.1186/s40494-018-0179-0) (cit. na s. 3).
- Xu, Xiang et al. (2018). „Regional clustering-based spatial preprocessing for hyperspectral unmixing“. In: *Remote Sensing of Environment* 204. May 2016, s. 333–346. ISSN: 00344257. DOI: [10.1016/j.rse.2017.10.020](https://doi.org/10.1016/j.rse.2017.10.020) (cit. na s. 5).