

České vysoké učení technické v Praze
Fakulta elektrotechnická

Katedra teorie obvodů
Program: Lékařská elektronika a bioinformatika



**Aplikace hyperspektrálního
snímání v medicíně
Application of hyperspectral
imaging in medicine**

BAKALÁŘSKÁ PRÁCE

Vypracovala: Emina Ganibegović
Vedoucí projektu: Ing. Lukáš Krauz
Rok: 2023

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Ganibegović** Jméno: **Emina** Osobní číslo: **484286**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra teorie obvodů**
Studijní program: **Lékařská elektronika a bioinformatika**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Aplikace hyperspektrálního snímání v medicíně

Název bakalářské práce anglicky:

Application of hyperspectral imaging in medicine

Pokyny pro vypracování:

Na základě literární rešerše podejte přehled přístupů a aplikací hyperspektrálního snímání využívaného v medicíně. Kromě jednotlivých aplikací se zvláště zaměřte na konstrukce daných hyperspektrálních systémů a algoritmy využívané k analýze multidimenzionálních, především hyperspektrálních, medicínských dat. Prozkoumejte možnosti volně dostupných hyperspektrálních databází obsahující medicínské snímky z různých typů měření, případně zvažte možnosti využití laboratorního hyperspektrálního systému (Specim PFD4K-65-V10E) pro medicínské aplikace. Dle provedené literární rešerše a konzultace s vedoucím práce vyberte vhodné algoritmy ke zpracování získaných vlastních či externích hyperspektrálních medicínských snímků. Zvolené metody analýzy medicínských hyperspektrálních dat ve vhodném programovém prostředí aplikujte a následně vyhodnoťte.

Seznam doporučené literatury:

- [1] Lu, G.; Fei, B. (2014). Medical hyperspectral imaging: a review. Journal of biomedical optics, 19(1), 010901.
- [2] Amigo, J.M., 2019. Hyperspectral imaging. Elsevier.
- [3] Chang, C. I. (2013). Hyperspectral data processing: algorithm design and analysis. John Wiley & Sons.
- [4] Bankman, I. (Ed.). (2008). Handbook of medical image processing and analysis. Elsevier.
- [5] Kowrowski, R. (2017). Processing of Hyperspectral Medical Images.
- [6] Krauz, L.; Páta, P.; Kaiser, J. (2022) Assessing the Spectral Characteristics of Dye- and Pigment-Based Inkjet Prints by VNIR Hyperspectral Imaging. Sensors

Jméno a pracoviště vedoucí(ho) bakalářské práce:

Ing. Lukáš Krauz katedra radioelektroniky FEL

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

Datum zadání bakalářské práce: **02.02.2022**

Termín odevzdání bakalářské práce: **10.01.2023**

Platnost zadání bakalářské práce: **30.09.2023**

Ing. Lukáš Krauz
podpis vedoucí(ho) práce

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

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

III. PŘEVZETÍ ZADÁNÍ

Studentka bere na vědomí, že je povinna vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studentky

Prohlášení

Prohlašuji, že jsem svou bakalářskou práci vypracovala samostatně pod vedením vedoucího práce a použila jsem pouze odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu literatury na konci práce v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne

.....
Emina Ganibegović

Poděkování

Děkuji Ing. Lukáši Krauzovi, za vedení mé bakalářské práce a za podnětné návrhy, které ji obohatily.

Emina Ganibegović

Název práce:

Aplikace hyperspektrálního snímání v medicíně

Autor: Emina Ganibegović

Studijní program: Lékařská elektronika a bioinformatika

Druh práce: Bakalářská práce

Vedoucí práce: Ing. Lukáš Krauz

Katedra radioelektroniky, FEL ČVUT v Praze

Abstrakt:

Bakalářská práce se zabývá využitím hyperspektrálního zobrazování v oblasti medicíny. Teoretická část práce je zaměřena na základní principy hyperspektrálního zobrazování, jeho konstrukci a aplikace v medicíně a také přehled dostupných datových sad. V praktické části práce byly implementovány a porovnány klasifikační metody. Pro tuto bakalářskou práci byl porovnán Support Vector Machine a spektrální metriky.

Klíčová slova: Hyperspektrální snímání, aplikace hyperspektrálního snímání, medicínské aplikace, analýza dat

Title:

Application of hyperspectral imaging in medicine

Author: Emina Ganibegović

Abstract:

The bachelor thesis deals with the use of hyperspectral imaging in the field of medicine. The theoretical part of the thesis is focused on the basic principles of hyperspectral imaging, its construction and applications in medicine, as well as overview of available datasets. In the practical part of the thesis, classification methods were implemented and compared. For this bachelor thesis Support Vector Machine and spectral metrics were compared.

Key words: Hyperspectral Imaging, application of hyperspectral imaging, medical applications, data analysis

Obsah

Seznam obrázků	ix
Úvod	1
1 Snímání spektra	3
1.1 Elektromagnetické vlny	3
1.2 Elektromagnetický spektrum	3
1.3 Spektroskopie	4
1.3.1 Spektrometr	4
1.3.2 Disperze	4
1.4 Spektrální reflektance	5
1.4.1 Difrakce	5
1.4.2 Refrakce	5
1.4.3 Absorpce	6
1.5 Optika tkáně	6
2 Hyperspektrální snímání	7
2.1 Multispektrální snímání	7
2.2 Hyperspektrální snímání	8
2.3 Metody snímání	9
2.3.1 Whiskbroom	10
2.3.2 Pushbroom	10
2.3.3 Staring	10
2.3.4 Snapshot	10
2.4 Spektrální reflektance	11
2.4.1 Spektrální podpisy	12
2.5 Aplikace	13
2.5.1 Zemědělství	13
2.5.2 Potraviny	14
2.5.3 Vojenství	15
3 Aplikace hyperspektrálního snímání v medicíně	17
3.1 Diagnostika	17
3.1.1 Detekce rakoviny	18
3.1.2 Monitorování ran	19
3.1.3 Patologie srdce a krevního oběhu	20
3.1.4 Onemocnění sítnice	21
3.2 Chirurgické vedení	22
3.3 Databáze	23
3.3.1 Databáze obrazu lidského mozku in-vivo pro detekci rakoviny mozku	23
3.3.2 Hyperspektrální soubor dat prekancerózních lézí u rakoviny žaludku a měřítka pro patologickou diagnostiku	24

3.3.3	Multidimenzionální databáze Choleloch a měřítka pro diagnostiku cholangiokarcinomu	24
4	Systémy pro medicínské aplikace	27
4.1	Úvod	27
4.2	Zdroj světla	28
4.2.1	Halogenové žárovky	28
4.2.2	LED	28
4.2.3	Lasery	29
4.3	Zařízení pro rozptyl vlnových délek	29
4.3.1	Laditelný filtry	29
4.3.2	Hranol-mřížka-hranol	30
4.3.3	Monochromátory	30
4.3.4	Interferometry	30
4.4	Detektory	30
5	Zpracování hyperspektrálních snímků vybraných databází	33
5.1	Spektrální rozsah	33
5.2	Předzpracování	33
5.3	Vybraná data z databází	34
5.4	Klasifikace	34
5.4.1	SVM	34
5.4.2	Aplikace spektrálních metrik	37
5.4.3	SID	38
5.4.4	SAM	39
5.4.5	SIDSAM	40
5.4.6	JMSAM	41
	Závěr	43
	Bibliografie	45
	Přílohy	53
A	Metriky	53
B	SVM	54

Seznam obrázků

1.1	Elektromagnetické spektrum [2]	4
1.2	Refrakce světla [6]	5
2.1	Srovnání mezi hypercube a RGB obrazem. [7]	7
2.2	Reprezentace metod pro získávání trojrozměrných hyperspektrálních krychlí s prostorovými (x, y) i spektrálními (λ) informacemi. [8]	9
2.3	Signatury spektrální odrazivosti zdravé vegetace, suché půdy, šedé podestýlky, vody a sněhu. [13]	11
2.4	Proces získávání ROI spekter listů a kořenů řepky olejky [15]	13
2.5	Hodnocení mrazivého poranění okurek pomocí HSI (a) obraz vzorku (b) klíčové kroky procesu analýzy obrazu [19]	14
2.6	Detekce pozemních min pomocí HSI [9]	15
3.1	Postup HS akvizice povrchu mozku in vivo. (a) Hyperspektrální akviziční systém používaný během procesu akvizice v neurochirurgické operaci. (b) Hyperspektrální snímky získané akvizičním systémem při různých vlnových délkách od pacienta postiženého glioblastomovým nádorem. c) datová kostka HSI. (d) RGB obraz vytvořený z HS kostky s markerem nádorové tkáně (vlevo) a markerem normální tkáně (vpravo) umístěnými na povrchu mozku. (e) a (f) Histopatologické snímky vzorku nádorové tkáně (glioblastom) a vzorku normální tkáně, v daném pořadí. [35]	23
3.2	Příklad scény datové sady PLGC. Hyperspektrální datová kostka je zobrazena v levém horním rohu a skládá se z dvourozměrné prostorové informace a jednorozměrné spektrální informace. V pravém horním rohu se zobrazí RGB obrázek odpovídající stejnému poli hyperspektrální datové krychle. Je vybrána podmnožina tří pásem z hyperspektrálních dat, aby se vygeneroval pseudobarevný obrázek, který se zobrazí v pravém dolním rohu. [36]	24
3.3	Scéna s multidimenzionálním obrazem datové sady. (a) RGB snímek, (b) mikroskopická hyperspektrální datová krychle, (c) 16 jednopásmových snímků extrahovaných z hyperspektrální datové krychle. [37]	25
4.1	Schéma hlavních komponent hyperspektrálního zobrazovacího systému. [39]	27
5.1	RGB anotovaný obrázek F_1	34
5.2	Střední spektra reflektance získaná z obrázku F_1	35
5.3	Lineární model SVM. Klasifikovaný lineárně separovatelná data.[55]	36

5.4	Confusion matrix získaná pomocí algoritmu SVM. Confusion matrix je tabulka, která se používá k definování výkonu klasifikačního algoritmu. Vizualizuje a shrnuje výkon klasifikačního algoritmu. Má čtyři druhy výsledků diskutovaných výše (skutečně pozitivní, falešně negativní, falešně pozitivní a pravdivé negativní) spolu s pozitivní a negativní klasifikací.	37
5.5	Ground truth a předpověď získaná pomocí algoritmu SVM. Většina tříd byla v tomto scénáři správně označena, což vedlo k vysoké přesnosti klasifikace.	38
5.6	Mean spectra a endmembers pro F_1	39
5.7	Predikce tříd pomocí spektrální metrické metody SID	40
5.8	Predikce tříd pomocí spektrální metrické metody SAM	40
5.9	Predikce tříd pomocí spektrální metrické metody SIDSAM.	41
5.10	Predikce tříd pomocí spektrální metrické metody JMSAM.	42

Úvod

Tato práce si klade za cíl v první části přiblížit téma hyperspektrálního snímání. Nejprve bude popsána teoretická podstata, vysvětlen princip snímání a přiblíženy jednotlivé metody snímání. Praktická část diplomové práce si klade za cíl nejprve popsat a ověřit široce používané algoritmy pro klasifikaci hyperspektrálních obrazů.

Hyperspektrální snímání je součástí třídy technik běžně označovaných jako spektrální zobrazování nebo spektrální analýza. Vzniklo z dálkového průzkumu Země a bylo zkoumáno pro různé aplikace. Hyperspektrální snímání je zachycení a zpracování obrazu při velmi velkém počtu spektrálních kanálů, analyzuje široké spektrum světla namísto pouhého přiřazení primárních barev (červená, zelená, modrá) každému pixelu.

V hyperspektrálním zobrazování jsou spektrální a prostorové podpisy kombinovány a vytvářejí 3D hyperspektrální datovou kostku. Dvě prostorové souřadnice v rovině popisují polohu, zatímco třetí souřadnice poskytuje spektrální podpis molekul v buňkách a tkáních. Každý pixel obrazu nese určitý spektrální podpis.

Jako nově vznikající zobrazovací modalita pro lékařské aplikace hyperspektrálního snímání má velký potenciál pro diagnostiku ne-invasivních onemocnění a chirurgické vedení.

V tomto projektu mým cílem bude popsat teoretickou podstatu, vysvětlit princip snímání a shrnout jednotlivé metody hyperspektrálního snímání.

Předkládaný projekt je uspořádán následovně. V Kapitole 1, bude uveden teoretický základ. Kapitola 2 věnujeme vysvětlením samotného principu Hyperspektrálního snímání. V Kapitole 3 představujeme nejpozoruhodnějších aplikací v oboru se zaměřením na biomedicínu i uvádíme přehled několika vybraných databází, které se zaměřují na biomedicínské aplikace. Kapitola 4 je věnována konstrukci hyperspektrálních zobrazovacích systémů používaných v lékařských aplikacích.

Hlavním cílem této práce bylo představit hyperspektrální zobrazování používané v lékařských aplikacích. Dalším cílem byla analýza dostupných medicínských datových souborů, která byla realizována pomocí programu MATLAB.

Kapitola 1

Snímání spektra

1.1 Elektromagnetické vlny

Energie se šíří ve formě vln, které se projevují jako příčné postupné vlnění vektorů elektrického (\mathbf{E}) a magnetického (\mathbf{H}) pole. Přičemž platí, že vektory elektrického a magnetického pole leží v rovinách kolmých ke směru šíření vlny (vlnový vektor \mathbf{k}) a jsou vzájemně na sebe kolmé. Každá elektromagnetická vlna se prostorem šíří s určitou frekvencí f , vlnovou délkou λ a rychlostí c . Vlna se šíří ve vakuu rychlostí $c = 299792458 \text{ ms}^{-1}$ (přibližně $3 \cdot 10^8 \text{ ms}^{-1}$). Šíření elektromagnetického vlnění je definováno dle Maxwellových rovnic (Rovnice 1). [1]

$$\begin{aligned}\nabla^2 \cdot \mathbf{B} &= \mu_0 \varepsilon_0 \frac{\vartheta^2 \cdot \mathbf{B}}{\vartheta \cdot t^2} \\ \nabla^2 \cdot \mathbf{E} &= \mu_0 \varepsilon_0 \frac{\vartheta^2 \cdot \mathbf{E}}{\vartheta \cdot t^2}\end{aligned}\tag{1.1}$$

1.2 Elektromagnetický spektrum

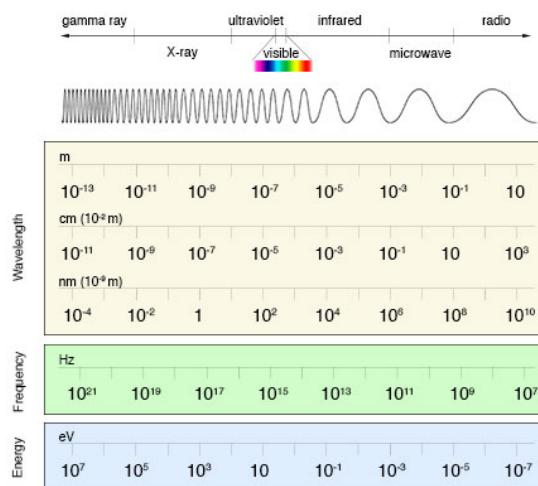
Elektromagnetické spektrum zahrnuje vlnové délky elektromagnetického záření v rozsahu od krátkovlnných (vysokofrekvenčních) gama paprsků po dlouhovlnné (nízkofrekvenční) rádiové vlny. Spektrum lze obecně rozdělit na rádiové vlny, mikrovlnné vlny, infračervené vlny, viditelné světlo, ultrafialové záření, rentgenové záření a gama záření. Optické senzory se používají k měření ultrafialových, viditelných a infračervených vlnových délek a mikrovlnné senzory se používají pro mikrovlnnou část elektromagnetického spektra. Elektromagnetické spektrum lze vyjádřit energií, vlnovou délkou nebo frekvencí. [2]

$$\lambda = \frac{c}{\nu}\tag{1.2}$$

Kde λ je vlnová délka, c je rychlost světla $299792458 \text{ ms}^{-1}$, ν je frekvence

$$E = h \cdot \nu\tag{1.3}$$

Kde λ je vlnová délka, c je rychlost světla $299792458 \text{ ms}^{-1}$, ν je frekvence.



Obrázek 1.1: Elektromagnetické spektrum [2]

1.3 Spektroskopie

Spektroskopie je technika štěpení světla (elektromagnetického záření) na jeho základní vlnové délky (spektrum). Energetické hladiny elektronů v atomech a molekulách jsou kvantovány a k absorpci a emisi elektromagnetického záření dochází pouze při specifických vlnových délkách. V důsledku toho nejsou spektra hladká, ale přerušovaná „čarami“ absorpce nebo emise.

Spektroskopie starého stylu byla provedena pomocí hranolu a fotografických desek. V dnešní době moderní spektroskopie využívá k rozptýlení světla difrakční mřížky, které se pak promítají na CCD (Charge Coupled Devices) podobné těm, které se používají v digitálních kamer. 2-rozměrná spektra jsou snadno extrahována z tohoto digitálního formátu a upravena tak, aby vytvořila 1-rozměrná spektra. [3]

1.3.1 Spektrometr

Hyperspektrální obrazy jsou vytvářeny přístroji nazývanými zobrazovací spektrometry. Spektrometr umožňuje měření spektra světla či elektromagnetického záření. Tyto komplexní senzory byly vyvinuty pomocí dvou související, ale odlišné technologie, spektroskopie a vzdálené zobrazování Země.

1.3.2 Disperze

Viditelné světlo, také známé jako bílé světlo, se skládá z kolekce barevných složek. Tyto barvy jsou často pozorovány, když světlo prochází trojúhelníkovým hranolem. Při průchodu hranolem se bílé světlo rozdělí na jednotlivé barvy - červenou, oranžovou, žlutou, zelenou, modrou a fialovou. Rozdělení viditelného světla do jeho různých barev je známé jako disperze.

Různé materiály se od sebe odlišují odlišnou optickou hustotou. Optická hustota je měřítkem tendence materiálu zpomalovat světlo, když jím prochází. Disperze je způsobena rychlostí šíření vlny na vlnové délce. Každá barva je charakteristická pro odlišnou vlnovou frekvenci a různé frekvence světelných vln se budou ohýbat v různé míře při průchodu hranolem.[4]

1.4 Spektrální reflektance

Spektrální reflektance, neboli spektrální odrazivost je množství odraženého záření. Lze je definovat jako poměr intenzity odraženého záření (M_r) a intenzity záření dopadajícího (M_i) na určité vlnové délce (λ) udávaný v procentech, tedy

$$p(\lambda) = \frac{M_r(\lambda)}{M_i(\lambda)} \cdot 100[\%] \quad (1.4)$$

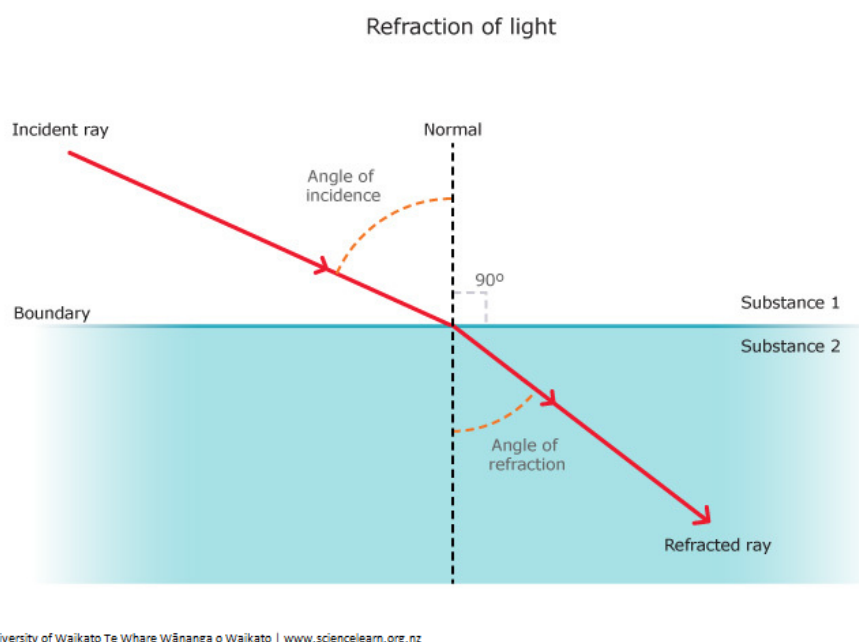
Každá látka se vyznačuje svoji vlastní spektrální charakteristikou, tedy unikátním spektrálním podpisem.

1.4.1 Difrakce

K difrakci dochází, když se světelné paprsky setkají s určitými strukturami. Běžná situace je ohyb světla na štěrbíně, kde se paprsky světla mohou šířit také do oblasti stínu překážky. Dopadne-li světlo na štěrbinu, bude se šířit za ní na základě Huygensova principu. V každodenním životě se jen zřídka setkáme s výraznými difrakčními efekty světla, tyto efekty jsou velmi běžné v optice a laserové technologii. Difrakce hraje zásadní roli v mnoha zařízeních, jako jsou optické rezonátory a vlákna. [5]

1.4.2 Refrakce

Lom je ohyb světla (dochází k němu také jiných vln), když prochází z jedné průhledné látky do druhé. Naše oči jsou závislé na tomto ohybu světla. Bez lomu bychom nebyli schopni zaostřit světlo na naši sítnici.



Obrázek 1.2: Refrakce světla [6]

Světlo se láme, kdykoli se pohybuje pod úhlem do látky s jiným indexem lomu (optická hustota). Tato změna směru je způsobena změnou rychlosti. Například,

když se světlo šíří ze vzduchu do vody, zpomaluje se, což způsobí, že pokračuje v cestě pod jiným úhlem nebo směrem. Refrakce lze použít k rozkladu světla pomocí hranolu, kde je bílé světlo rozloženo na jeho spektrum.[6]

Když paprsek vstoupí do hustší látky (vyšší index lomu), „ohýbá se“ směrem k normální čáře. Úhel refrakce určuje Snellův zákon. Index lomu je definován jako poměr rychlosti světla ve vakuu k rychlosti světla v daném médiu.

1.4.3 Absorpce

Absorpce je jev v kterém dochází k pohlcení světla (místo odražení nebo lomu) objektem v průběhu jeho šíření se prostoru. Pro absorpci je potřeba aby byl vyšší počet valenčních elektronů na nižších hladinách. Absorbance udává jaké množství přímého světla je pohlceno objektem.

Měření absorbance na mnoha vlnových délkách umožňuje identifikaci látky pomocí absorpční spektroskopie, kdy je vzorek osvětlen z jedné strany a je měřena intenzita světla, které ze vzorku vychází v každém směru.

1.5 Optika tkáně

Šíření světla v tkáni je významným problémem v lékařských aplikacích a ve vývoji diagnostických metod. Světlo vstupující do biologické tkáně prochází několika rozptylovými a absorpčními událostmi. Biologické tkáně mají heterogenní složení s prostorovými variacemi optických vlastností. K rozptylu dochází tam, kde existuje prostorová variace indexu lomu. V buněčných médiích jsou důležitými rozptyly subcelulární orgány. Hloubka průniku světla do biologických tkání závisí na tom, jak silně tkáň absorbuje světlo. Většina tkání jsou dostatečně slabí absorberé, tím umožňují významné pronikání světla v rozmezí od 600 do 1300 nm. Molekuly absorbují fotony, když se jejich energie shoduje s intervalem mezi stavy vnitřní energie. Během absorpčního zpracování mohou přechody mezi dvěma energetickými hladinami molekuly sloužit jako spektrální podpis molekuly.

Tkáňové komponenty absorbující světlo se nazývají chromofory. Pro viditelné vlnové délky, nejdůležitější chromofory jsou krev a melanin. Primárními absorberé pro UV vlnové délky jsou proteiny a aminokyseliny, zatímco chromoforem pro infračervené vlnové délky je voda.

Světlo absorbované složkami tkáně je buď přeměněno na teplo, nebo vyzařováno ve formě luminiscence, včetně fluorescence a fosforescence. Dopadající světlo, obvykle v oblasti UV nebo VIS, vzrušuje molekuly tkáně a indukuje fluorescenční emise. Nejběžnějšími fluorofory ve strukturní matici jsou kolagen a elastin, zatímco převládajícími fluorofory podílejícími se na buněčném metabolismu jsou nikotinamidadeninindinukleotid (NADH), flavinadeninindinukleotid (FAD) a lipopigmenty. Buňky v různých chorobných stavech mají často různé struktury nebo podléhají různým rychlostem metabolismu, což má za následek různá fluorescenční emisní spektra. Proto fluorescenční zobrazování umožňuje vyšetřovat tkáň na diagnostiku onemocnění v reálném čase bez podávání exogenních fluorescenčních látek.

Reflektivní zobrazování může detekovat místní změny v rozptylových a absorpčních vlastnostech tkáně a fluorescenční zobrazování může zkoumat změny v biochemickém složení tkáně odhalením úrovní endogenních fluoroforů. [7]


Kapitola 2

Hyperspektrální snímání

2.1 Multispektrální snímání

Hyperspektrální snímání souvisí s multispektrálním snímáním, proto je potřebou před definicí pojmu hyperspektrální snímání uvést pojem multispektrální snímání.

Multispektrální zobrazování má za cíl získat prostorové a spektrální informace, které jsou přímo užitečné pro aplikace v reálném čase v oboru. Multispektrální zobrazování je technika, která zahrnuje získávání a analýzu snímků pořízených při různých vlnových délkách elektromagnetického spektra. To umožňuje vytvářet podrobné mapy různých fyzikálních vlastností zobrazovaných objektů. Proces obecně zahrnuje rychlé získávání obrazu a jednoduché algoritmy pro zpracování obrazu a rozhodování. Snížení celkového objemu dat je klíčem k vybudování efektivních multispektrálních zobrazovacích systémů. V praxi to znamená pořizování snímků s relativně nízkým prostorovým rozlišením na několika důležitých vlnových délkách.[8]



Obrázek 2.1: Srovnání mezi hypercube a RGB obrazem. [7]

Multispektrální zobrazovací systémy získávají data v malém počtu spektrálních pásů. Většina multispektrálních zobrazovacích systémů používá pro pozorování scény tři až šest spektrálních pásem s velkými intervaly optických pásem, od viditelných až po blízké infračervené oblasti elektromagnetického spektra. Takto nízký počet spektrálních pásem je však limitujícím faktorem pro rozlišení různých materiálů. [9]

2.2 Hyperspektrální snímání

Na rozdíl od multispektrálního snímání hyperspektrální zobrazování rozděluje obraz na desítky nebo stovky barev. Pásem je obvykle násobně více, záleží na parametrech daného hyperspektrálního systému. Šířka pásma se pohybuje od 1 do 15 nanometrů. Jednotlivá pásma jsou přilehlá a tvoří tak souvislé spektrum.

Hyperspektrální zobrazování zachycuje jak spektrální (λ), tak prostorové (x, y) informace a spojuje je do 3D datové matice nazývané „hyperspektrální datová krychle“ (hypercube). Hyperspektrální datová krychle je 3D datová struktura, která představuje hyperspektrální obraz. Obsahuje dvě prostorové dimenze (x a y) a jednu spektrální dimenzi (λ). Každý pixel na obrázku je reprezentován řadou spektrálních hodnot, jedna pro každou vlnovou délku v rámci celého analyzovaného spektra. Hypercube umožňuje analýzu a manipulaci se spektrálními informacemi v rámci obrazu. [10]

Nezákladnějším procesním krokem, který se provádí na datové krychli, je převedení naměřených hodnot odražené intenzity na spektra reflektance korekci pro spektrální citlivost systému, běžně dosahované pomocí referenčního standardního měření odraznosti. Tato spektra lze dále převést na absorpční použitím záporného logaritmu odrazivosti. Interpretace těchto výsledků a kvantifikaci vlastností tkání lze poté dosáhnout pomocí modelů interakce světlo-tkáň nebo technik data science. [7, 11]

Standardní HSI systém se skládá z pěti hlavních komponent: světelný zdroj, čočky objektivu, hyperspektrální senzor, zobrazovací spektrograf a počítač. Světelné zdroje pro aplikace spektrálního zobrazování lze obecně rozdělit do dvou kategorií: zdroje osvětlení a zdroje buzení. Širokopásmová světla se obecně používají jako zdroje osvětlení pro zobrazování odrazivosti a propustnosti. Jako zdroje buzení se běžně používají úzkopásmová světla. Některé biologické materiály při excitaci monochromatickým světlem o vysoké intenzitě vyzařují světlo o nízké intenzitě v širokém rozsahu vlnových délek.

Disperzní prvky jsou základní složkou spektrálních zobrazovacích systémů. Jejich funkcí je rozptylovat širokopásmové světlo do různých vlnových délek a promítat rozptýlené světlo do plošných detektorů. Zobrazovací spektrograf je optické zařízení, které rozptyluje širokopásmové světlo do různých vlnových délek z různých prostorových oblastí cíle. Od tradičního spektrografu se liší tím, že může přenášet i prostorové informace. Většina zobrazovacích spektrografů je postavena na difrakčních mřížkách, které zahrnují dva hlavní typy: transmisní a odrazové mřížky. [8]

Podle druhu snímaného spektra, hyperspektrální snímání se dá rozdělit na několik oblastí podle délky infračerveného záření. Krátkovlnné infračervené pásmo (SWIR - short-wave infrared region), které odpovídá 1 - 3 μm . Středovlnné infračervené pásmo (MWIR - mid-wave infrared region) odpovídající 3 - 5 μm . Dlouhovlnné infračervené pásmo (LWIR - long-wave infrared region) odpovídající 8 - 14 μm , a nakonec viditelné blízké infračervené pásmo (VNIR - visible near-infrared region), s velikostí 0.3 - 1 μm .

Hyperspektrální snímání je v podstatě kombinací spektroskopie a zobrazovací techniky. Na základě typu spektroskopie můžeme rozlišit několik typů hyperspektrálního zobrazování.

Odráživé hyperspektrální zobrazování, kde se jedná o zachycení světla, které se odráží od objektu nebo scény. Odráživé hyperspektrální zobrazování se používá v

různých aplikacích, včetně průzkumu nerostů, zemědělství a monitorování životního prostředí.


Emisní hyperspektrální zobrazování, jedná se o zachycení světla, které je vyzařováno objektem nebo scénou.

Fluorescenční hyperspektrální zobrazování zahrnuje zachycení a analýzu světla, které je vyzařováno objektem nebo scénou, když je vybudena specifickou vlnovou délkou světla. To může poskytnout cenné informace o chemickém složení objektu nebo scény, protože různé materiály budou fluoreskovat na různých vlnových délkách.

Ramanovo hyperspektrální zobrazování je typ hyperspektrálního zobrazování, které zahrnuje zachycení světla, které je rozptýleno objektem nebo scénou, když je vybudena specifickou vlnovou délkou světla. Tento rozptyl světla je známý jako Ramanův rozptyl a je způsoben vibracemi molekul uvnitř objektu nebo scény. Ramanovo hyperspektrální zobrazování lze použít k identifikaci konkrétních materiálů a jejich chemického složení, protože Ramanovo spektrum každého materiálu je jedinečné. Často se používá v oblastech, jako je věda o materiálech, chemie a biologie, k analýze vzorků a identifikaci konkrétních sloučenin.

2.3 Metody snímání

Hyperspektrální zobrazování se často používá ke shromažďování snímků s vysokým prostorovým a spektrálním rozlišením pro základní výzkum. Proces obvykle vyžaduje značné množství času pro získání obrazu v laboratorních podmínkách a poměrně komplikované postupy pro offline analýzu obrazu. Obecně existují tři přístupy pro získávání 3D hyperspektrálních krychlí [hypercubes (x, y, λ)]. Jedná se o metody bodového skenování, řádkového skenování, plošného skenování a snapshot.



Obrázek 2.2: Reprezentace metod pro získávání trojrozměrných hyperspektrálních krychlí s prostorovými (x, y) i spektrálními (λ) informacemi. [8]

Na jedné straně jsou metody bodového i řádkového skenování metodami prostorového skenování. Metoda plošného skenování (tj. metoda sekvenčního pásma) je na druhé straně metodou spektrálního skenování. [8]

2.3.1 Whiskbroom

V metodě bodového skenování (tj. metoda whiskbroom) je jeden bod snímán podél dvou prostorových dimenzí (x, y) pohybem buď vzorku nebo detektoru. V whiskbroom byla často používána rotující zrcadla ke skenování. Rotující zrcadla přeměrovávají odražené světlo do bodu, kde je seskupen jeden nebo jen několik sensorových detektorů. Poté je odražené světlo rozptýleno disperzním prvkem (hranolem) a zaznamenáno detektorem s lineárním polem. Spektrální obrazové datové kostky (x, y, λ) lze získat skenováním přes 2D scénu (x, y) a rozptýlením v doméně vlnových délek (λ) . K získání jediného spektra pro každý pixel ve scéně se používá spektrofotometr vybavený bodovým detektorem. Hyperspektrální obrazová data se shromažďují pixel po pixelu. Dvouosé motorizované polohovací stoly jsou obvykle potřebné k pohybu vzorku nebo detektoru k dokončení skenování kompletní scény. V whiskbroom jsou k dokončení získávání obrazu obvykle potřeba dvouosé motorizované polohovací stoly, což komplikuje konfiguraci hardwaru. Snímání metodou whiskbroom je časově náročnější, jelikož je třeba pohybovat se v obou osách (x, y) . [8, 12]

2.3.2 Pushbroom

Metoda řádkového skenování (tj. metoda pushbroom) je rozšířením metody bodového skenování. Namísto skenování vždy jednoho bodu tato metoda současně získává šterbinu prostorových informací a také úplné spektrální informace pro každý prostorový bod v lineárním zorném poli. Postupně je pořízen speciální 2D snímek (y, λ) s jedním prostorovým rozměrem (y) a jedním spektrálním rozměrem (λ) . Při skenování šterbiny ve směru pohybu (x) se získá úplná hyperkrychle. Hyperspektrální systémy využívající zobrazovací spektrografy pracují v režimu řádkového skenování. Pushbroom skener může získat více světla než whiskbroom, protože může zůstat v určité oblasti delší dobu, což poskytuje dlouhou expozici na maticovém detektoru a také relativně vysoké spektrální rozlišení. [8, 12]

2.3.3 Staring

Metoda staring (také známý jako pásmová sekvenční metoda) je metoda spektrálního skenování, která získává jednopásmový 2D obraz ve stupních šedi (x, y) s plnou prostorovou informací najednou. Tento režim obecně používá filtry, jako jsou filtrová kola obsahující pevné pásmové filtry, lineární proměnné filtry (LVF), variabilní interferenční filtr (VIF) a laditelné filtry, namísto mřížky nebo hranol před maticovým detektorem. Světlo prochází zaostřovací optikou. Poté je filtrován, což indukuje pouze úzkopásmový segment spektra, který dopadá na ohniskovou rovinu detektoru (typicky maticový CCD). Proto lze 2D obraz v jedné vlnové délce zachytit v daném čase a obrazová kostka je vyplněna vyladěním výstupní vlnové délky filtru jako funkce času. Počet získaných spektrálních pásem je zcela na uživateli. [12]

2.3.4 Snapshot

Metoda snapshot (také známá jako single-shot) je určena k záznamu prostorových i spektrálních informací na plošném detektoru s jednou expozicí. Na rozdíl od whiskbroom, pushbroom a staring, které potřebují skenovat buď v


prostorové dimenzi, nebo ve spektrální dimenzi, čímž omezují jejich časové rozlišení, je snapshot zobrazovací technikou bez nutnosti skenování vůbec. Pro rozklad světla se využívají hranoly, mřížky nebo hologram. Nevýhodou této metody je nižší spektrální a prostorové rozlišení oproti předchozím metodám a omezenější počet spektrálních pásem. [12]

2.4 Spektrální reflektance

V hyperspektrálním snímání se nejčastěji používá reflektanční spektroskopie. Proto pro hyperspektrální snímání podstatnou vlastností je spektrální odrazivost. Spektrální odrazivost může být definována jako poměr odražené energie k dopadající energii jako funkce vlnové délky.

Spektrální odrazivost je míra podílu dopadajícího elektromagnetického záření, které se odráží od povrchu, jako funkce vlnové délky. Obvykle se vyjadřuje jako procento nebo zlomek mezi 0 a 1, přičemž 0 znamená, že se neodráží žádné světlo a 1 znamená, že se odráží všechno světlo. Spektrální odrazivost lze měřit pro povrchy ve viditelném spektru (vlnové délky přibližně 400 nm až 700 nm) i v jiných částech elektromagnetického spektra, jako je ultrafialová (UV) a infračervená (IR) oblast.

Každý materiál odráží, rozptyluje, vyzařuje a absorbuje elektromagnetické záření na různých specifických vlnových délkách. Z toho důvodu každý materiál má jedinečnou křivku spektrální odrazivosti.



Obrázek 2.3: Signatury spektrální odrazivosti zdravé vegetace, suché půdy, šedé podestýlky, vody a sněhu. [13]

Výrazné výchylky spektrálních křivek směrem dolů označují rozsahy vlnových délek, pro které materiál selektivně absorbuje dopadající energii. Tyto vlastnosti se běžně nazývají absorpční pásy. Celková tvar spektrální křivky a poloha a síla absorpčních pásů mohou být v mnoha případech použity k identifikaci a rozlišení různých materiálů. Absorpční spektra se běžně měří pomocí transmitance.

$$p(\lambda) = \frac{M_r(\lambda)}{M_i(\lambda)} \cdot 100[\%] \quad (2.1)$$

Spektrální odrazivost povrchu je závislá na jeho fyzikálních a chemických vlastnostech, stejně jako na úhlu dopadu přicházejícího světla.

Spektrální odrazivost je důležitou vlastností povrchů, která se používá v různých aplikacích, včetně dálkového průzkumu Země, kolorimetrie a materiálových věd. Používá se také ke stanovení odrazivosti povrchů v různých částech elektromagnetického spektra, což lze využít k identifikaci materiálů a stanovení jejich fyzikálních a chemických vlastností.

Při hyperspektrálním zobrazování se spektrální odrazivost používá k analýze složení povrchů a materiálů. Hyperspektrální krychle obsahuje informace o spektrální odrazivosti povrchu u každého pixelu, které lze použít k identifikaci materiálů přítomných ve scéně a jejich relativního množství. To se provádí porovnáním naměřené spektrální odrazivosti povrchu se známými spektry různých materiálů.

Kromě identifikace materiálů lze hyperspektrální zobrazování použít také k extrakci dalších informací o povrchu, jako je jeho textura, drsnost a obsah vlhkosti. Používá se v různých aplikacích, včetně průzkumu nerostů, zemědělství a monitorování životního prostředí.

Existuje několik různých typů reflektanční spektroskopie, včetně difuzní reflektanční spektroskopie, spektroskopie zrcadlové odraznosti a spektroskopie obousměrné reflektance distribuční funkce (BRDF). Každá z těchto technik měří odrazivost povrchu jiným způsobem a používají se v různých aplikacích.

Reflektanční spektroskopie se používá v různých oblastech, včetně dálkového průzkumu Země, materiálové vědy a kolorimetrie. Používá se také ve farmaceutickém průmyslu k identifikaci a charakterizaci složení tablet a jiných pevných lékových forem. Reflektanční spektroskopii lze provádět pomocí spektrometrů nebo hyperspektrálních zobrazovačů, což jsou specializované přístroje, které měří odrazivost povrchu v rozsahu vlnových délek. [14]

2.4.1 Spektrální podpisy

Spektrální podpis je jedinečná sada měření spektrální odrazivosti, která charakterizuje konkrétní materiál nebo povrch. Je to grafické znázornění odrazivosti materiálu jako funkce vlnové délky a lze jej použít k identifikaci materiálu a určení jeho fyzikálních a chemických vlastností.

Spektrální podpisy jsou důležité při dálkovém průzkumu Země, protože je lze použít k rozlišení mezi různými materiály a povrchy na základě jejich odrazových charakteristik. Například různé typy vegetace mají jedinečné spektrální podpisy, které lze použít k identifikaci a mapování různých typů vegetace na snímku. [13]

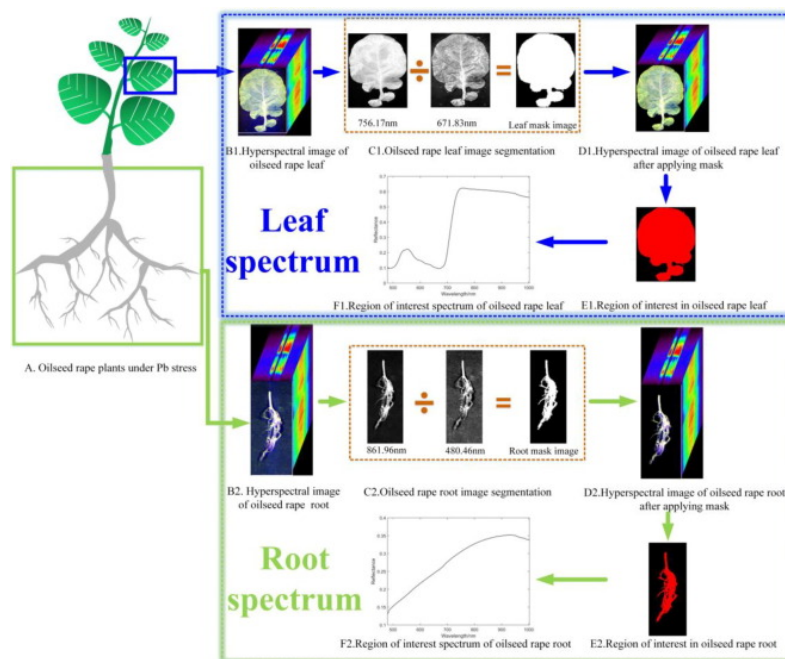
Spektrální podpisy lze měřit pomocí spektrometrů nebo hyperspektrálních zobrazovačů, což jsou specializované přístroje, které měří odrazivost povrchu v rozsahu vlnových délek. Výsledná data jsou typicky vynesena jako spektrum odrazivosti, což je graf ukazující odrazivost materiálu jako funkci vlnové délky.

2.5 Aplikace

Hyperspektrální zobrazování, které bylo poprvé vyvinuto pro dálkový průzkum, dnes našlo své využití v různých oblastech. V zemědělství, HSI lze použít ke sledování zdraví plodin a k identifikaci problémů, jako jsou škůdci, choroby a nedostatek živin. V potravinářství, HSI lze použít k identifikaci a klasifikaci různých typů potravinářských výrobků, stejně jako k detekci vad nebo kontaminantů. Ve vojenství, HSI lze použít k detekci skrytých objektů, jako jsou zbraně nebo výbušné materiály, stejně jako k identifikaci kamufláže a dalších skrytých materiálů. V lékařství, HSI lze použít k ne-invazivnímu posouzení zdraví tkání a k identifikaci abnormální tkáně, jako jsou rakovinné nádory. Tato kapitola přiblíží některé konkrétní aplikace v praxi.

2.5.1 Zemědělství

V zemědělství lze hyperspektrální zobrazování použít ke sledování zdraví plodin a k identifikaci problémů, jako jsou škůdci, choroby a nedostatek živin.



Obrázek 2.4: Proces získávání ROI spekter listů a kořenů řepky olejky [15]

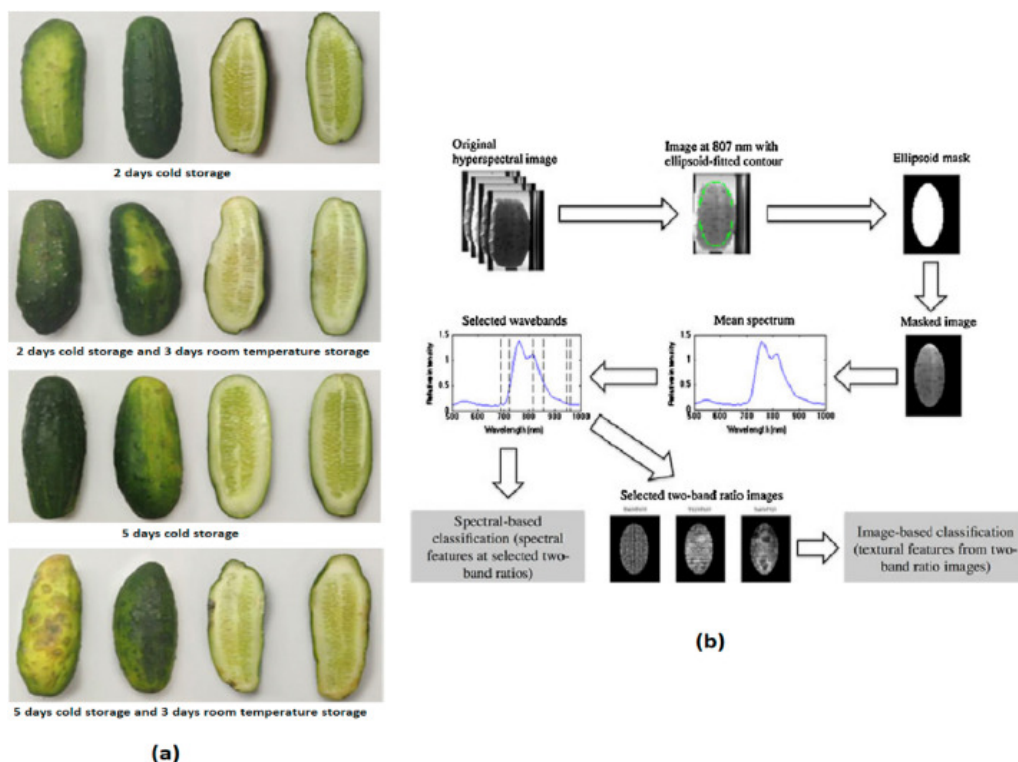
Jednou z klíčových výhod hyperspektrálního zobrazování v zemědělství je jeho schopnost poskytnout podrobné informace o biochemickém složení rostlin. Analýzou absorpce a rozptylu světla na různých vlnových délkách je možné identifikovat specifické molekuly a struktury v rostlinách, jako je chlorofyl a další pigmenty. Tyto informace lze použít k posouzení celkového zdraví rostliny a k identifikaci jakýchkoli problémů, které mohou ovlivnit její růst nebo vývoj.

Hyperspektrální zobrazování bylo kromě jeho použití při monitorování zdraví plodin také použito k identifikaci a mapování různých typů vegetace a ke sledování změn krajinného pokryvu v čase. Byl také zkoumán jako potenciální nástroj pro precizní zemědělství, protože může poskytnout podrobné informace o zdraví a potřebách jednotlivých rostlin, které lze použít k optimalizaci postupů zavlažování a hnojení.

Celkově má hyperspektrální zobrazování potenciál být cenným nástrojem v zemědělství, protože může poskytnout podrobné informace o zdraví a potřebách plodin a může pomoci optimalizovat zemědělské postupy. [16] [17]

2.5.2 Potraviny

Jednou z klíčových aplikací HSI v potravinářství je kontrola kvality. HSI lze například použít k detekci přítomnosti cizích předmětů, jako jsou kovové úlomky, v potravinářských výrobcích. Může být také použit k identifikaci zralosti ovoce nebo přítomnosti kažení potravinářských výrobků. [18]



Obrázek 2.5: Hodnocení mrazivého poranění okurek pomocí HSI (a) obraz vzorku (b) klíčové kroky procesu analýzy obrazu [19]

Kromě použití při kontrole kvality se HSI používá také k analýze nutričního obsahu potravinářských výrobků. Analýzou absorpce a rozptylu světla na různých vlnových délkách je možné identifikovat specifické molekuly a struktury v potravinářských produktech, jako jsou bílkoviny, sacharidy a tuky. Tyto informace lze použít k posouzení nutriční hodnoty potravinářských výrobků jak identifikaci případných zdravotních přínosů nebo rizik.

Hyperspektrální zobrazování je ne-invasivní a nedestruktivní metoda bez chemikálií a vyžaduje minimální přípravu vzorku. Proto šetří práci, čas a náklady na činidla ve srovnání s tradičními metodami, v důsledku toho je ekonomickým řešením. Mezi nevýhody patří obrovské množství nadbytečných dat, a je třeba zlepšit hardwarovou rychlost hyperspektrálního zobrazovacího systému pro rychlou analýzu dat.


Celkově má HSI potenciál být cenným nástrojem v potravinářských vědách, protože může poskytnout podrobné informace o chemických a fyzikálních

vlastnostech potravinářských produktů a může pomoci zajistit kvalitu a bezpečnost těchto produktů. [20]

2.5.3 Vojenství

Ve vojenství lze HSI použít pro různé účely, včetně:

Detekce skrytých objektů: HSI lze použít k detekci objektů, které mohou být skryté, jako jsou zbraně nebo výbušné materiály. Analýzou absorpce a rozptylu světla na různých vlnových délkách je možné identifikovat specifické molekuly a struktury, které mohou být přítomny v těchto objektech.



Obrázek 2.6: Detekce pozemních min pomocí HSI [9]

Identifikace kamuflážních a tajných materiálů: HSI lze použít k identifikaci materiálů, které jsou navrženy tak, aby splývaly s okolím, jako jsou maskovací nebo stealth materiály. Analýzou spektrálního podpisu těchto materiálů je možné je detekovat a sledovat, i když jsou vizuálně obtížně viditelné.

Mapování terénu: HSI lze použít k vytvoření podrobných map terénu, včetně prvků, jako je vegetace, vodní útvary a geologické struktury. Tyto informace lze použít k plánování vojenských operací jak identifikaci potenciálních hrozeb nebo příležitostí.

Monitorování prostředí: HSI lze použít ke sledování známek potenciálních hrozeb v prostředí, jako jsou chemické nebo biologické látky, nebo ke sledování pohybu osob nebo vozidel. [21]

Kapitola 3

Aplikace hyperspektrálního snímání v medicíně

Hyperspektrální zobrazování jako bezkontaktní, nekomplikovaná zobrazovací měřicí metoda je v současné době intenzivně se rozvíjející oblastí pro různé lékařské aplikace. Hyperspektrální zobrazování se stále více používá pro lékařskou diagnostiku a chirurgii řízenou obrazem, a nachází uplatnění i v širších oblastech medicíny.

3.1 Diagnostika

Hyperspektrální snímání má obrovský potenciál ve screeningu, detekci a diagnostice onemocnění, protože má schopnost detekovat biochemické změny v důsledku vývoje onemocnění.

Hloubka průniku do biologické tkáně ve viditelném a blízkém infračerveném spektrálním rozsahu umožňuje získávání informací s vysokou klinickou hodnotou účinkem specifického rozptylu a absorpce tkáňovými složkami.

V lékařské diagnostice lze hyperspektrální zobrazování použít k identifikaci abnormalit ve tkáních, jako jsou rakovinné nádory, a ke sledování účinnosti léčby.

Jednou z klíčových výhod hyperspektrálního zobrazování je jeho schopnost poskytnout podrobné informace o biochemickém složení tkání. Analýzou absorpce a rozptylu světla na různých vlnových délkách je možné identifikovat specifické molekuly a buněčné struktury v tkáních. To může pomoci odlišit normální tkáň od abnormální a může také poskytnout vhled do základních biologických procesů, které se vyskytují v tkáni.

Kromě použití v diagnostice rakoviny se hyperspektrální zobrazování také používá k identifikaci dalších abnormalit ve tkáních, jako jsou infekce, záněty a vaskulární problémy. Byl také zkoumán jako potenciální nástroj pro sledování postupu hojení ran a pro identifikaci problémů, jako jsou kazy nebo onemocnění dásní v ústech.

Celkově má hyperspektrální zobrazování potenciál být cenným nástrojem v lékařské diagnostice, protože může poskytnout podrobné informace o biochemickém složení tkání a může pomoci identifikovat abnormality, které nemusí být viditelné pomocí jiných zobrazovacích technik.

3.1.1 Detekce rakoviny

Jedním z nejnáročnějších problémů v lékařských postupech při diagnostice nebo léčbě nádorů je segmentace nádorů kvůli nejednoznačnosti mezi rakovinnou a nerakovinnou přilehlou tkání. Téměř u všech endoskopických a laparoskopických výkonů se chirurgové potýkají s problémem detekce a lokalizace nádorů před biopsií, stanovení hranice pro resekci a zhodnocení resekční plochy po extrakci nádoru. Rutinně používanými diagnostickými nástroji u pacientů s podezřením na rakovinu jsou zobrazovací techniky, jako je radiografie. Diagnóza je však subjektivní, a proto vyžaduje odborný úsudek.

Včasná detekce může znamenat obrovský rozdíl, protože léčba rakoviny je často jednodušší a účinnější, když je diagnostikována v rané fázi. Metody detekce rakoviny mohou lékařům pomoci diagnostikovat rakovinu, disekovat maligní oblast s bezpečným okrajem a zhodnotit ložisko nádoru po resekci. [22]

Rakovina žaludku je hlavním problémem veřejného zdraví jako čtvrtá nejčastější rakovina a druhá hlavní příčina úmrtí na rakovinu na celém světě. V roce 2015 Goto et al. shromáždili hyperspektrální snímky ve spektrálním rozsahu mezi 400 a 800 nm z ex-vivo tkáňových vzorků žaludku, aby provedli studii žaludečních nádorů odstraněných endoskopickou submukózní disekcí od 96 různých pacientů. Systém byl schopen získat hyperspektrální snímky s prostorovým rozměrem 480×640 pixelů. Pomocí těchto snímků byli schopni určit optimální vlnovou délku, která umožnila nejpřesnější klasifikaci mezi nádorem a normální sliznicí pomocí Mahalanobisovy vzdálenosti, která v tomto případě byla 770 nm . Získané výsledky senzitivity, specifity a přesnosti byly 71%, 98% a 85%. Studie odhalily slibné výsledky v použití HSI jako diagnostického nástroje pro rakovinu žaludku. [23]

Rakovina prsu je nejrozšířenějším onemocněním u žen ve vysoce i méně rozvinutých zemích, kde je včasná detekce životně důležitá pro záchranu života a rychlé zotavení.

V roce 2020 Araf et al. vytvořili dvě různá nastavení systému využívající hyperspektrální kameru a více zdrojů excitace s vlnovou délkou (380-1050 nm) pro terapii a diagnostiku rakoviny prsu. První nastavení (Transmission Mode) bylo použito pro měření propustnosti světla ex vivo vzorku prsu. Byly provedeny výpočty absorpce vzorku. Druhé nastavení (Reflection Mode) bylo použito pro měření difuzní odrazivosti světla vzorku prsu. Výsledky obou nastavení byly použity k výběru optimálního spektrálního obrazu pro rozlišení mezi normálními a nádorovými oblastmi ve vzorku prsu ex vivo zkoumáním spektroskopie optických vlastností v blízkém a viditelném (NIR-VIS) spektru. Vlastní systém byl aplikován na techniku případové studie pro detekci nádoru prsu. Výsledky sledované případové studie byly působivé pro výběr optimální vlnové délky pro diagnostiku a léčbu (680, 760 nm). Výsledky segmentovaných spektrálních oblastí (420-620 nm) byly účinné pro odlišení rakovinné oblasti od normální tkáně s 95% a 96% senzitivitou a specificitou. [24]

Akbari et al. navrhli použití pokročilé metody zpracování a klasifikace obrazu za účelem analýzy hyperspektrálních obrazových dat pro detekci rakoviny prostaty. Spektrální signatury byly extrahovány a vyhodnoceny v rakovinné i normální tkáni. Pro klasifikaci hyperspektrálních dat byly vyvinuty a vyhodnoceny podpůrné vektorové stroje nejmenších čtverců, aby se zlepšila detekce rakovinné tkáně. Tato metoda byla použita k detekci rakoviny prostaty u myši s nádorem a

na patologických preparátech prostaty získaných od čtyř pacientů. Pro zachycení hyperspektrálních obrazových dat byly použity dva kamerové systémy CRi (Caliper, Hopkinton, MA); pro skenování zvířat byl použit in vivo zobrazovací systém a pro skenování patologických preparátů byl použit mikroskopický zobrazovací systém. Požadovaný rozsah vlnových délek je definován jako mezi 450 a 950 nm. Předběžné výsledky s 11 myšmi ukázaly, že senzitivita a specificita metody klasifikace hyperspektrálních snímků je 92,8% až 2,0% a 96,9% až 1,3%. [25]

3.1.2 Monitorování ran

Stanovení hloubky popálenin je v klinické praxi stále výzvou a základem pro optimální léčbu. Odhad míry poškození se obvykle stále provádí bez jakýchkoli objektivních pomůcek nebo technických metod, pouze na základě subjektivních dojmů (barevných), rekapilačních testů, bolesti a osobních zkušeností. Hyperspektrální zobrazování má vysoký potenciál etablovat se jako nová bezkontaktní měřicí metoda v medicíně.

Remisní spektra jsou zaznamenávána ve spektrálním rozsahu od 500 do 1000 nm s rozlišením 5 nm, plocha měření je cca. 20–30 cm, standardní velikost obrazu je 640 × 480 pixelů, záznam potřebuje cca. 5 s. Data byla naměřena od 43 pacientů. Pro analýzu perfuze popálenin byla použita speciální vlastní metoda zpracování dat. Prezentovaná metoda HSI umožňuje podrobnou a kvantifikovanou analýzu a srovnání reakcí na ránu, například pro vývoj optimalizovaných léčebných strategií a metod založených na důkazech. Z hyperspektrálních spekter lze odhadnout parametry 3D perfuze a objektivně popsat mikrocirkulaci popálenin během prvních 72 hodin po tepelném poškození. [26]

Diabetická ulcerace nohy je hlavní komplikací diabetu a diabetických pacientů. Pokud se diabetické vředy na noze neléčí, mohou se infikovat a vyžadovat celkovou nebo částečnou amputaci postižené končetiny. Změny velkých cév a mikrocirkulace diabetické nohy jsou důležité při vzniku ulcerace diabetické nohy a následného nezhojení již existujících ulcerací. Khaodhiar et al. použili lékařskou hyperspektrální technologii k vyhodnocení mikrocirkulačních změn u diabetických vředů na nohou a k předpovědi klinických výsledků.

Deset pacientů s diabetem 1. typu s 21 místy vředů na nohou, 13 pacientů s diabetem 1. typu bez vředů a 14 nediabetických kontrolních subjektů bylo pozorováno až 4krát během 6měsíčního období.

Hyperspektrální měření okysličení tkání pozorovalo změny ve tkáni bezprostředně obklopující vřed při srovnání vředů, které se hojí, a vředů, které se nehojí ($P < 0,001$). Senzitivita, specificita a pozitivní a negativní prediktivní hodnoty HSI indexu pro predikci hojení byly 93, 86, 93 a 86%, v tomto pořadí, při hodnocení na snímcích pořízených při první návštěvě.

Tato zjištění mohou mít důležité klinické důsledky, protože naznačují, že jedno měření HSI při první návštěvě pacienta nebo měření HSI každých několik měsíců u pomalu se hojících nebo nehojících se vředů může lékaři pomoci s diagnózou, volbou terapie a terapeutickým sledováním. [27]

Ve studii z roku 2016 Zherdeva et al. prezentovali analýzu hyperspektrálního zobrazování pro in vivo vizualizaci kožních novotvarů. Pro in vivo studii byly zobrazeny kožní nádory a okolní zdravá tkáň u 45 pacientů. Bylo testováno 16 melanomů, 19 bazaliomů a 10 benigních nádorů s různými stádii růstu novotvaru.

Systém HSI poskytuje snímky kožní tkáně se spektrálním rozlišením 5 nm v rozsahu 450-750 nm s automatickou stabilizací každého snímku kompenzující posun snímané oblasti v důsledku spontánních makropohybů pacienta. Integrované optické hustoty v rozmezích 530-600 a 600-670 nm se používají pro zobrazování distribuce hemoglobinu a melaninu v kožní tkáni v reálném čase.

Bylo prokázáno, že celková přesnost identifikace rakoviny kůže přesahuje 90% a 70% pro odlišení melanomů od BCC a benigních nádorů. Byla prokázána možnost HSI klasifikace melanomů různých stadií. [28]

3.1.3 Patologie srdce a krevního oběhu

Léčba srdečních arytmií často zahrnuje ablací životaschopné svalové tkáně uvnitř nebo v blízkosti ostrůvků zjizveného myokardu. Přesto dnes existují omezené prostředky, kterými lze hranice takových jizev zobrazit během operace a odlišit je od míst akutního poranění způsobeného radiofrekvenční (RF) ablací.

Swift a kol. v roce 2018 prozkoumala metodologii hyperspektrálního zobrazování (HSI) k vymezení a rozlišení jizevnaté tkáně od poškození tkáně způsobeného RF ablací. To bylo studováno in vivo na krysách. RF ablace ventrikulárního povrchu živých krys, které podstoupily torakotomii, byla následována 2měsíčním obdobím zotavení zvířat. Během druhé operace byly nové RF léze umístěny vedle zjizvené tkáně z předchozího ablačního postupu. Jako alternativní způsob vytvoření jizvy byl použit model infarktu myokardu.

Excitačně-emisní matrice získané z míst RF lézí, oblasti jizvy a okolní neablatované tkáně odhalily mnohočetné spektrální změny. Hyperkrychle obsahující vlnové délky v rozmezí od 420 do 720 nm byly shromážděny pomocí systému Nuance FX HSI. HSI založená na autofluorescenci umožnila odlišit místa RF lézí od jizvy nebo neablatovaného myokardu u potkanů s otevřeným hrudníkem. Pilotní verze perkutánního HSI katétru byla použita k prokázání proveditelnosti vizualizace RF lézí v síňové tkáni živých prasat.

HSI založená na změnách tkáňové autofluorescence je vysoce účinným nástrojem pro odhalení – in vivo a s vysokým prostorovým rozlišením – povrchových hranic jizvy myokardu a její rozlišení od oblastí akutní nekrózy způsobené RF ablací. [29]

V jiné studii bylo provedeno, zda hyperspektrální zobrazování mohlo přesně posoudit přítomnost nebo nepřítomnost PAD a přesně předpovědět závažnost PAD.

Periferní arteriální onemocnění (PAD) zahrnuje aterosklerotickou okluzi arteriálního oběhu do dolní končetiny, což může vést k klidovým bolestem, ulceraci dolní končetiny a dokonce amputaci končetiny. Účinné diagnostické a prognostické technologie jsou nezbytné pro časnější detekci a léčbu, aby se předešlo zbytečným komplikacím a intervencím.

Tato prospektivní studie Chin et al. zahrnovala pacienty během 10týdenního období pro studii tepen dolních končetin, včetně kotník-pažního indexu (ABI) a Dopplerových křivek. Pacienti s edémem dolních končetin byli vyloučeni. Do studie bylo zařazeno 126 pacientů (252 končetin). Po vyloučení 15 pacientů bylo 111 pacientů ponecháno k analýze, včetně 46 (92 končetin) pacientů bez PAD a 65 (130 končetin) pacientů s PAD. Pacienti podstoupili hyperspektrální zobrazení v devíti angiosomech na každé končetině. Další místa byla zobrazena, když byla přítomna ztráta tkáně. Lékařské záznamy zapsaných pacientů byly přezkoumány z hlediska demografických údajů, aktivních léků, chirurgické anamnézy a dalších informací souvisejících s PAD. Pacienti byli rozděleni do skupin bez PAD a PAD.

Rozdíly v hyperspektrálních hodnotách mezi skupinami byly hodnoceny pomocí dvoustranného t testu. Analýza rozdílů hodnot v různých závažnostech PAD, jak je definována třífázovými, dvoufázovými nebo monofázickými Dopplerovými křivkami, byla provedena pomocí jednosměrné analýzy rozptylu. Hyperspektrální hodnoty byly korelovány s ABI pomocí Pearsonova bivariačního lineárního korelačního testu. Hodnoty deoxyhemoglobinu pro angiosomy plantární metatarzální, klenby a paty byly významně odlišné mezi pacienty s PAD a bez PAD. Průměrné hodnoty deoxyhemoglobinu pro stejné tři angiosomy ukázaly významné rozdíly mezi pacienty s monofázickými, bifázickými a trifázickými křivkami. U pacientů s PAD také existovala významná korelace mezi hodnotami deoxyhemoglobinu a ABI pro stejné tři angiosomy. Hodnoty oxyhemoglobinu nepředpovídaly přítomnost nebo nepřítomnost PAD, nekorelovaly se závažností PAD a nekorelovaly s ABI. Tyto výsledky naznačují schopnost hyperspektrálního zobrazování detekovat přítomnost PAD. Hyperspektrální měření mohou také vyhodnotit různé závažnosti PAD. [30]

3.1.4 Onemocnění sítnice

Hyperspektrální zobrazování je velmi slibné pro detekci a klasifikaci několika onemocnění, zejména pro ne-invazivní oční diagnostiku. Vzhledem k tomu, že světlo odražené od struktur sítnice (např. makula) má často jedinečné spektrální znaky, které jsou běžně považovány za spojené se specifickými očními chorobami, schopnost identifikace těchto spektrálních znaků *in vivo* bude mít v klinické diagnostice vysokou hodnotu.

V roce 2012, Gao et al. představili snímek hyperspektrální sítnicové kamery s Image Mapping Spectrometer (IMS) pro aplikace zobrazování oka. Výsledný systém je schopen současně pořídít 48 spektrálních kanálových snímků v rozsahu $470\text{ nm}–650\text{ nm}$ se snímkovou frekvencí 5,2 fps. Prostorové vzorkování každé měřené spektrální scény je 350×350 pixelů. Výhodou tohoto zařízení pro snímky je eliminace pohybových artefaktů oka a problémů s chybnou registrací pixelů v tradičních hyperspektrálních sítnicových kamerách založených na skenování a zobrazování dynamiky saturace kyslíkem v reálném čase s časovým rozlišením pod sekundu. Výkon spektrálního zobrazování je demonstrován v experimentu zobrazování lidské sítnice *in vivo*. Pomocí tohoto zařízení byli schopni úspěšně získat absorpční spektrální podpisy oxy-hemoglobinu a makulárních pigmentů. [31]

V roce 2010 Nourrit a kol. vyvinuli hyperspektrální kameru s vysokým prostorovým a spektrálním rozlišením v celém viditelném spektru, kterou lze upravit ze standardní fundus kamery. Hyperspektrální technika umožňuje vlnově specifickou vizualizaci retinálních lézí, které mohou být neviditelné pomocí kamery zdroje bílého světla.

Pro prozkoumání praktické proveditelnosti vývoje hyperspektrální kamery z fundus kamery Zeiss a pro ilustraci jejího použití při zobrazování pacientů s diabetickou retinopatií a glaukomem byla pořizena série osmi snímků na vlnových délkách 495 až 720 nm a doba záznamu byla kratší než 1,6 s. Úroveň světla na rohovce byla pod limity ANSI a pacienti hodnotili měření jako velmi pohodlné. Snímky byly vysoké kvality a byly použity k vytvoření mapy okysličení hlavy optického nervu pixel-to-pixel. [32]

3.2 Chirurgické vedení

V chirurgickém vedení může být hyperspektrální zobrazování použito k poskytování informací v reálném čase o tkáni, na kterou je chirurgický zákrok zaměřen nebo ovlivněn. To může pomoci chirurgům přesněji lokalizovat a zaměřit se na specifické struktury v těle a může také pomoci minimalizovat riziko poškození zdravé tkáně.

Jednou z klíčových výhod hyperspektrálního zobrazování v chirurgickém vedení je jeho schopnost poskytnout podrobné informace o biochemickém složení tkání. Analýzou absorpce a rozptylu světla na různých vlnových délkách je možné identifikovat specifické molekuly a buněčné struktury v tkáních. To může pomoci odlišit normální tkáň od abnormální a může také poskytnout vhled do základních biologických procesů, které se vyskytují v tkáni.

Celkově má hyperspektrální zobrazování potenciál být cenným nástrojem v chirurgickém vedení, protože může poskytnout informace v reálném čase o cílové tkáni a může pomoci minimalizovat riziko poškození zdravé tkáně. [33]

Nádory mozku způsobují celosvětově 2 až 3% úmrtí na rakovinu. Chirurgie je vedle radioterapie a chemoterapie jednou z hlavních možností léčby mozkových nádorů. Pouhé oko chirurga však často nedokáže přesně rozlišit mezi nádorem a normální mozkovou tkání, protože mozkové nádory infiltrují a difundují do okolního normálního mozku. Při neurochirurgii je časté, že se odebere příliš mnoho normální mozkové tkáně (tzv. bezpečnostní okraj) nebo že nádorová tkáň neúmyslně zůstane pozadu (tzv. reziduální tumor). Několik studií prokázalo, že reziduální nádor je nejčastější příčinou recidivy nádoru a je hlavní příčinou morbidit a mortality. Naproti tomu bylo prokázáno, že nadměrná resekce tkáně mozkového nádoru způsobuje trvalé neurologické poškození, které ovlivňuje kvalitu života pacientů.

Studie s cílem vyřešit výše uvedené problémy související s intraoperační detekcí a vymezením mozkových nádorů, byly provedeny v rámci evropského projektu HELICoiD (HypErspectraL Imaging Cancer Detection-618080), jehož hlavním cílem bylo pomocí hyperspektrálního zobrazování zobecnit metodologii pro rozlišení mezi normálními a maligními tkáněmi v reálném čase během neurochirurgických výkonů. V těchto studiích byl pro identifikaci okrajů mozkového nádoru zkoumán vývoj algoritmů strojového/hlubokého učení pomocí HS snímků rakoviny mozku in vivo. Pro tento účel byl navržen a postaven intraoperační demonstrátor s cílem pořizovat intraoperační snímky HS a zpracovávat je v reálném čase, aby pomohl neurochirurgům při resekci. Tento demonstrátor byl schopen zachytit HS snímky ve spektrálním rozsahu mezi 400 a 1700 *nm* za přibližně 2 minuty pomocí dvou pushbroom kamer. Byly získány dvě HS kostky, jedna v rozsahu VNIR (400 až 1000 *nm*) tvořená 826 spektrálními pásy a vysokým prostorovým rozlišením 1004 × 1787 pixelů (129 × 230 *mm*) a další v rozsahu NIR (900 až 1700 *nm*) tvořená 172 spektrálními pásy a nízkým prostorovým rozlišením 320 × 479 pixelů (153 × 230 *mm*). Informace o rozsahu NIR však použili pouze ve dvou z předběžných studií. [34]

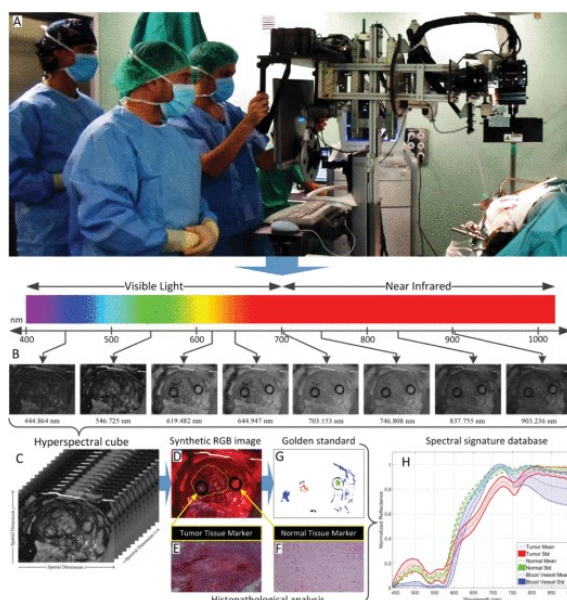
3.3 Databáze

Navzdory popularitě hyperspektrálního zobrazování existuje nedostatek veřejně dostupných souborů lékařských dat. Veřejné patologické datové sady poskytují velké množství dat pro hluboké učení, většina z nich se skládá z RGB snímků. V této kapitole bych ráda představila některé veřejně dostupné databáze lékařských hyperspektrálních dat.

3.3.1 Databáze obrazu lidského mozku in-vivo pro detekci rakoviny mozku

Práce měla za hlavní cíl aplikaci hyperspektrálního zobrazování k vymezení mozkových nádorů v reálném čase při neurochirurgických operacích. Pro tento výzkumný projekt byl vyvinut přizpůsobený intraoperační hyperspektrální systém akvizice. Hyperspektrální kamera je založena na technice pushbroom a pokrývá spektrální rozsah od 400 do 1000 nm. Pomocí toho systému byla vytvořena hyperspektrální databáze in vivo lidských mozkových tkání. Bylo získáno celkem 36 hyperspektrálních snímků od 22 různých pacientů. Z těchto dat bylo pomocí poloautomatické metodiky založené na algoritmu mapovače spektrálních úhlů označeno více než 300 000 spektrálních signatur. Byly definovány čtyři různé třídy: normální tkáň, nádorová tkáň, krevní céva a elementy pozadí.

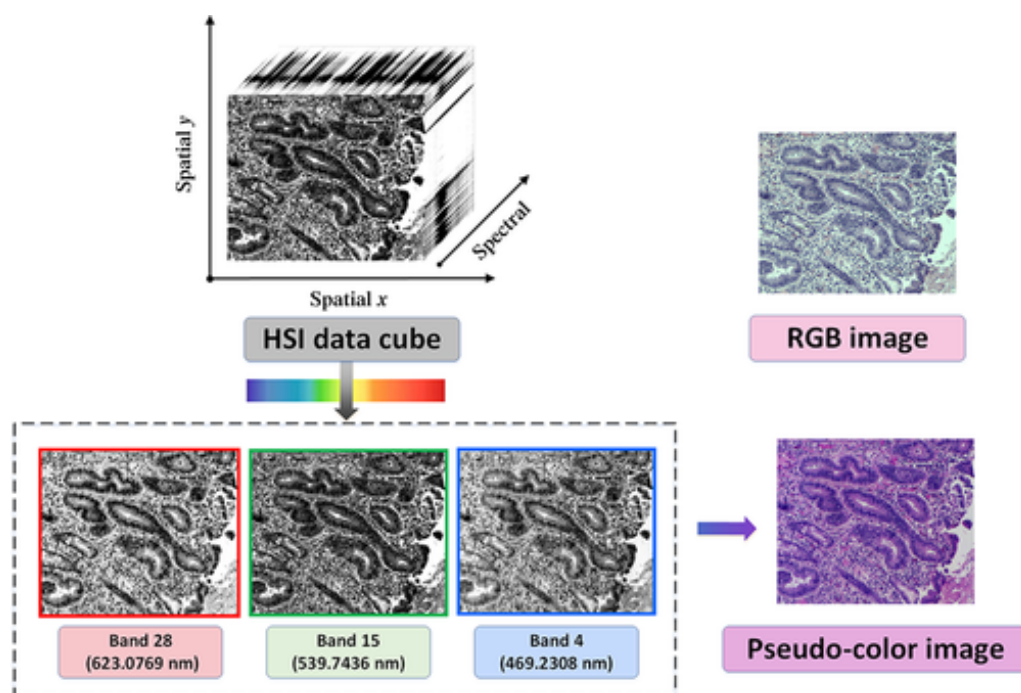
Všechna hyperspektrální data byla zpřístupněna ve veřejném úložišti.[35]



Obrázek 3.1: Postup HS akvizice povrchu mozku in vivo. (a) Hyperspektrální akviziční systém používaný během procesu akvizice v neurochirurgické operaci. (b) Hyperspektrální snímky získané akvizičním systémem při různých vlnových délkách od pacienta postiženého glioblastomovým nádorem. (c) datová kostka HSI. (d) RGB obraz vytvořený z HS kostky s markerem nádorové tkáně (vlevo) a markerem normální tkáně (vpravo) umístěnými na povrchu mozku. (e) a (f) Histopatologické snímky vzorku nádorové tkáně (glioblastom) a vzorku normální tkáně, v daném pořadí. [35]

3.3.2 Hyperspektrální soubor dat prekancerózních lézí u rakoviny žaludku a měřítko pro patologickou diagnostiku

Hyperspektrální datový soubor PLGC je získáván pomocí samostatně vyvinutého systému MHSI. Systém MHSI obsahuje optický mikroskop, halogenovou lampu jako zdroj světla, kameru se zařízením s barevným nábojem (color-CCD), kameru se zařízením s chlazeným šedým nábojem s vysokou hustotou (šedá-CCD), akustickou-optický laditelný filtr (AOTF), ovladač AOTF modelu bez specifických patogenů (SPF) a počítač.



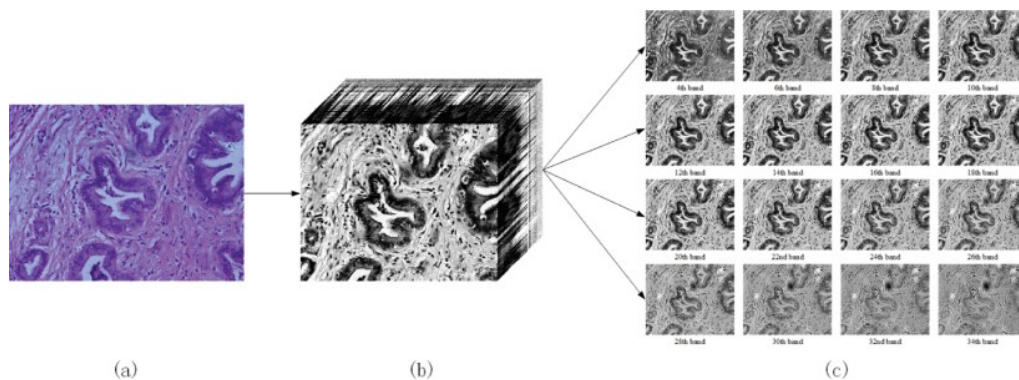
Obrázek 3.2: Příklad scény datové sady PLGC. Hyperspektrální datová kostka je zobrazena v levém horním rohu a skládá se z dvourozměrné prostorové informace a jednorozměrné spektrální informace. V pravém horním rohu se zobrazí RGB obrázek odpovídající stejnému poli hyperspektrální datové krychle. Je vybrána podmnožina tří pásem z hyperspektrálních dat, aby se vygeneroval pseudobarevný obrázek, který se zobrazí v pravém dolním rohu. [36]

Obrázky z datového souboru PLGC jsou shromážděny ze 74 sklíčků s žaludeční tkání. Pomocí systému MHSI je pořízeno celkem 924 párů efektivních scén při zvětšení $\times 10$, včetně snímků HSI a RGB. Zachycená hyperspektrální datová kostka obsahuje 40 pásem a spektrální rozsah 450 až 700 nm se spektrálním rozlišením 6,25 nm . Každý pás je obrázek ve stupních šedi a obsahuje 2048×2448 pixelů. Shromážděné scény jsou převážně z normální žaludeční tkáně a dvou typů tkání prekancerózních lézí, 414 scén IM a 181 scén GIN. [36]

3.3.3 Multidimenzionální databáze Choledech a měřítko pro diagnostiku cholangiokarcinomu

Multidimenzionální databáze choledechů obsahuje jak mikroskopické hyperspektrální snímky, tak RGB barevné snímky choledechových tkání zachycené

mikroskopickým hyperspektrálním zobrazovacím systémem. Tato databáze obsahuje 880 scén vícerozměrných snímků zachycených z tkání choledochu 174 pacientů. Mezi těmito vícerozměrnými obrázky je 689 scén, které obsahují část oblastí s rakovinou, 49 scén je plných oblastí rakoviny a 142 scén jsou obrázky bez oblastí rakoviny. [37]



Obrázek 3.3: Scéna s multidimenzionálním obrazem datové sady. (a) RGB snímek, (b) mikroskopická hyperspektrální datová krychle, (c) 16 jednopásmových snímků extrahovaných z hyperspektrální datové krychle. [37]


Kapitola 4

Systemy pro medicínské aplikace

4.1 Úvod

Přístrojové vybavení je klíčovým bodem každého spolehlivého měřicího systému. Přístupy založené na zobrazování a spektroskopii byly intenzivně zkoumány a vyvíjeny po mnoho let. Všechny HSI a MSI metody jsou kombinací mezi konvenčním zobrazováním a konvenční jednobodovou spektroskopií takovým způsobem, že umožňuje vytvořit HSI a MSI zařízení. Obecné konfigurace systému pro konvenční zobrazování, spektroskopii a hyperspektrální zobrazování jsou znázorněny na obrázku 4.1.

Základní nastavení HSI systému se skládá ze zdroje světla, adekvátní čočky objektivu, zařízení pro rozptyl vlnové délky a kamery s 2D detektorem. Tato kapitola se primárně zaměřuje na přístrojové vybavení pro techniku hyperspektrálního zobrazování s důrazem na ty, které našly uplatnění v lékařství. [38]



Obrázek 4.1: Schéma hlavních komponent hyperspektrálního zobrazovacího systému. [39]

4.2 Zdroj světla

Hlavním základem HSI a MSI je interakce světla s molekulami, které vzorek obsahuje. Tato interakce bude záviset na povaze vzorku (chemické interakce) a fyzikálních vlastnostech povrchu (mimo jiné drsnost, svazek, úroveň zhutnění).

Hyperspektrální systém je kombinací spektroskopie a zařízení na bázi vidění, z tohoto důvodu je výběr zdroje záření velmi důležitý. Při výběru světelného zdroje pro stolní hyperspektrální systémy je velmi důležité věnovat pozornost vlastnostem, jako je rozsah osvětlení. HSI vyžaduje větší množství světla kvůli různým procesům, kterými emitované světlo prochází. Po emisi světelných paprsků před nebo po interakci se vzorkem je světlo díky průchodu vzduchu rozptylovacím zařízením rozptýleno do úzkých vlnových délek. Kromě toho může být záření částečně absorbováno nebo odraženo. Z tohoto důvodu je potřeba větší množství světla. Optimální osvětlení by mělo být pokud možno homogenní a pokrývat co největší prostor bez poškození vzorku. Osvětlení závisí na geometrii vzorku a geometrii samotného světelného zdroje. Ve většině případů jsou světelné zdroje umístěny pod úhlem 45° stupňů ke vzorku.

Nejčastěji používanými osvětlovacími zařízeními pro spektrometrii jsou halogenové žárovky, LED a lasery. Kromě toho pro použití ve speciálních aplikacích existují xenonové výbojky[25], fluorescenční UV zářivky, low-pressure metal vapor lamps.

4.2.1 Halogenové žárovky

Halogenové žárovky, obecně halogenové žárovky s wolframem, lze použít v NIR, VIR a UV. Širokopásmové osvětlení halogenových žárovek je vhodné pro různé režimy snímání. Obecně dosází dobré výkony pro odrazové aplikace. Nicméně při implementaci žárovek s vysokou intenzitou by bylo možné dosáhnout také měření propustnosti. Hlavními výhodami halogenových žárovek je jejich komerční dostupnost, nízká cena a požadované nízké napětí a široký elektromagnetický rozsah (340-2500 nm; 29 500-4000 cm^{-1}). Je třeba poznamenat některé nevýhody. Tento zdroj osvětlení generuje vysokou úroveň energie, která vyvolává zahřívání vzorků. To může odhalit několik problémů ve vzorcích, jako jsou strukturální změny nebo dokonce vypalování. [40]

Halogenové žárovky nacházejí široké uplatnění v lékařských hyperspektrálních systémech. [22, 23]

4.2.2 LED

Ve srovnání s halogenovým výbojkami jsou LED světelné zdroje levnou alternativou. Dalšími výhodami LED osvětlení jsou vyšší účinnost, méně tepla a mnohem delší životnost lampy. Proto byly LED diody široce používány v lékařství[28] a průmyslu [41] jako zdroje osvětlení. Nevýhodou LED je však závislost jejich spektrálního chování na propustném proudu a teplotě jejich pájecího bodu [42]. Osvětlení LED tedy musí během procesu zobrazování stabilizovat oba parametry, aby se zabránilo kolísání špičkové vlnové délky jednotlivých spekter LED. I když LED diody vyzařují monochromatické světlo v oblasti VIS, existuje několik způsobů, jak je zkombinovat za účelem generování

bílého světla. V systémech HSI lze implementovat především dichromatické, trichromatické a ortetrachromatické přístupy [43].

4.2.3 Lasery

Na rozdíl od halogenových lamp a LED, které jsou vysoce implementovány pro viditelné a blízké infračervené HSI systémy v režimech odrazivosti a propustnosti, lasery jsou implementovány pro Ramanova a fluorescenční měření. Lasery jsou monochromatické zdroje s vysokým výkonem a směrovou energií, takže fungují jako správné zdroje buzení. V tomto případě jsou měření založena na změnách dopadajícího světla po interakci se vzorkem, pokud jde o intenzitu při různých vlnových délkách. Změny intenzity světla, také definované jako frekvenční posun, způsobují Ramanův rozptyl nebo fluorescenční emisi související s chemickým složením zkoumaného vzorku. Lasery byly implementovány v systému HSI jako kontinuální vlnové nebo pulzní emitory v různých Ramanových a fluorescenčních zobrazovacích aplikacích [44, 45, 46].

4.3 Zařízení pro rozptyl vlnových délek

Širokopásmové světlo emitované světelným zdrojem nebo odražené vzorkem, než dorazí k detektoru bude rozptýleno disperzními prvky. Tento jev je nezbytnou částí jakékoli hyperspektrálního a multispektálního systému. Zde se vcítíme do vlastností nejběžněji používaných disperzních zařízení, jako jsou variabilní a laditelné filtry, monohromátory a spektrometry s Fourierovou transformací.[47]

4.3.1 Laditelné filtry

Ve spektrálních skenovacích systémech, tj. plošném skenování, jsou variabilní nebo laditelné filtry běžně implementovány jako zařízení pro rozptyl vlnové délky a mohou být umístěny mezi vzorek a detektor nebo mezi osvětlovací systém a vzorek.

Spektrální přenos naladitelného filtru může být elektronicky řízen přivedením napětí, akustickým signálem atd. Spektrální laditelnosti lze dosáhnout mnoha způsoby. Diskutujeme tři třídy elektricky laditelných filtrů: zařízení s tekutými krystaly založená na dvojlomu, akusticko-optická zařízení založená na difrakci a stručně se také zmiňují o známějších filtrech typu interferometru [48].

Akustooptické laditelné filtry (AOTF) a laditelné filtry s tekutými krystaly (LCTF) se nejčastěji používají v mikroskopických systémech. AOTF využívají akustické vlnové frekvence k deformaci dvojlomného krystalu, normálně oxidu teluratého, který funguje jako mřížka rozptylováním světla v různých vlnových délkách v daném směru. Laditelný filtr z tekutých krystalů (LCFT) využívá elektronicky řízené LC prvky k přenosu zvolené vlnové délky [48].

Tradiční přístupy fluorescenční mikroskopie mohou detekovat jedno až několik spektrálních pásem pomocí pásmových filtrů s centrálními vlnovými délkami (CWL) odpovídajícími vlnovým délkám maximální emise specifických fluoroforů. Na rozdíl od tradiční fluorescenční mikroskopie, systémy hyperspektrální mikroskopie využívají různé technologie spektrálního filtrování, včetně mřížek, hranolů a laditelných filtrů [49]. LCTF byl použit ve studii uvedené v kapitole 3 [25, 29].

4.3.2 Hranol-mřížka-hranol

Hranol-mřížka-hranol (Prism-grating-prism) je přímá disperzní komponenta, která umožňuje HSI spektrografy pro průmyslové a výzkumné aplikace ve spektrálním rozsahu 320 až 2700 nm. Skládá se ze speciálně navržené, objemově propustné mřížky vlepené mezi dva téměř identické hranoly, s krátkými a dlouhými propustmi umístěnými mezi mřížkou a hranolem, aby blokovaly nežádoucí vlnové délky a zabraňovaly povrchovým odrazům. Tato disperzní složka je široce používána v menších levných hyperspektrálních kamerách. PGP byl použit ve výše zmíněné studii detekce rakoviny pomocí infračerveného hyperspektrálního zobrazování [22].

4.3.3 Monochromátory

Mezi hlavní typy monochromátorů patří optický hranol a difrakční mřížka, které jsou základními součástmi v systémech pushbroom HSI. Mřížka je struktura složená z propouštěcích nebo rozptylujících prvků oddělených v periodickém režimu, které jsou schopné rozdělit širokopásmové světlo do několika paprsků s vlastní amplitudou a fází. Při rozkladu světla pomocí hranolu se využívá lomu světla při přechodu z vnějšího prostředí do materiálu hranolu s jiným indexem lomu a opět ven z materiálu pod jiným úhlem podle Snellova zákona.

Při konstrukci monochromátorů existují dva hlavní přístupy: odrazové (reflexní) a propustné (transmisní) mřížky. Odrazová mřížka se skládá hlavně z odrazových optických komponent (zrcadla), rozlišující rovinné (konkávní) a zakřivené (konvexní) mřížky. Disperzní prvek je obecně tvořen transmisní mřížkou umístěnou mezi dvěma hranoly s integrací krátkých a dlouhých propustných filtrů. Světlo ze zdroje je kolimováno k prvnímu hranolu, odražený paprsek dopadá na mřížku a ohýbá světlo do druhého hranolu. [50]

Monochromátory byly použity v lékařských hyperspektrálních systémech.[28]

4.3.4 Interferometry

Interferometry jsou široce používány v infračervené a Ramanově spektroskopii. Jsou založeny na vlastní interferenci širokopásmového světla, které je rozděleno do dvou stejných paprsků a rekombinováno po různých drahách. Základem interferometru je, že jeden paprsek světla je vychýlen do pevného zrcadla a druhý je orientován na pohybující se zrcadlo. Paprsky se odrážejí zpět a rekombinují, ale změny vzdálenosti pohybujícího se zrcadla generují rozdíl v optické dráze a tím i interferenci, která je sbírána jako interferogram detektorem a převedena na spektrum pomocí Fourierovy transformace. [51]

4.4 Detektory

Detektory jsou navrženy tak, aby shromažďovaly dopadající světlo a převáděly jej na elektrické signály, které lze převést na vizuální interpretaci spektrálního podpisu. V HSI a MSI jsou detektory normálně namontovány ve tvaru architektury ohniskové roviny (FPA). FPA je snímací pole (obvykle obdélníkové) sestavené v ohniskové rovině zařízení, které se skládá ze stovek jednotlivých detektorů. Tyto detektory jsou skutečně ty, které mají na starosti transformaci přicházejícího světla

na elektronické impulsy. Na trhu existují dva hlavní polovodičové detektory, zařízení s nábojovou vazbou (CCD) a doplňkové detektory oxidu kovu a polovodičů (CMOS), spolu s hlavními variacemi obou architektur. CCD se skládají z mnoha fotodiod, které jsou složeny z materiálů citlivých na světlo, jako je křemík (Si), arsenid india a galia (InGaAs), antimonit india a telurid rtuť a kadmia (HgCdTe).[52]

Oba jsou široce používány v lékařských hyperspektrálních zobrazovacích systémech. [29, 25]

Kapitola 5

Zpracování hyperspektrálních snímků vybraných databází

Cílem této implementace je porovnat široce používané algoritmy pro klasifikaci hyperspektrálních dat. Za tímto účelem budeme přesně porovnávat Spectral Metrics a Support Vector Machine. Datový soubor [53] použitý v této práci obsahuje 14 hyperspektrálních snímků makety scény s anotovanými pixely, kde je viditelná krev a krvi podobné látky.

5.1 Spektrální rozsah

Spektrální rozsah se týká oblastí vlnových délek pokrytých systémy HSI. Nejpoužívanější spektrální rozsah v literatuře spadá do oblastí VIS a NIR. NIR spektrální zobrazování se spoléhá na podtónové a kombinované vibrační pásma a nízkoenergetické elektronické přechody v této oblasti, zatímco MIR zobrazování zaznamenává absorpenci světla na vibračních a rotačních frekvencích atomů v molekule.

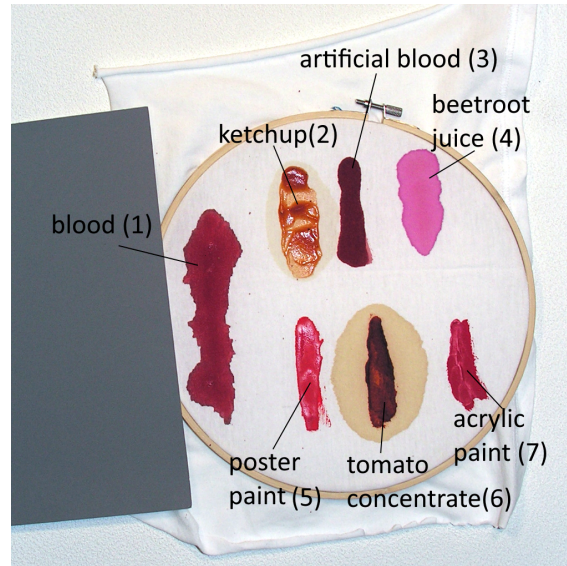
Většina snímků byla pořízena kamerou VNIR SOC-710 se spektrálním rozsahem 377-1046nm. Výstupní obraz má rozměry 696 × 520 se 128 pásmy a 12bitovým dynamickým rozsahem.

5.2 Předzpracování

Zachycené hyperspektrální snímky byly podrobeny standardnímu kalibračnímu postupu, včetně: odstranění tmavého rámečku, spektrální a radiometrické kalibrace a také normalizace odrazivosti pomocí šedého kalibračního panelu Munsel Color. Spektrální zkreslení je způsobeno především přístroji pro záznam dat, kolísáním světelného zdroje a povahou vzorku. Bez ohledu na spektrální techniku použitou pro získávání obrazu je nejběžnějším spektrálním problémem šum.[54] Hodnoty v datacubes jsou opravenou odrazivostí - podrobnosti o opravném algoritmu jsou v příslušném článku. [53]

5.3 Vybraná data z databází

Pro tento příklad uvedu klasifikaci na obrázku anotovanou jako F_1 . Tato scéna obsahuje krev a šest látek podobných krvi na kusu bílé látky. Látka byla napnuta na dřevěném rámu, aby se minimalizoval výskyt záhybů. Na dalších obrázcích jsou



Obrázek 5.1: RGB anotovaný obrázek F_1

znázorněna mean spektra každé třídy. Třídy jsou anotovány následovně 0 - pozadí 1 - krev 2 - kečup 3 - umělá krev 4 - šťáva z červené řepy 5 - plakátová barva 6 - rajčatový koncentrát 7 - akrylová barva 8 - nejistá krev Třídy byly autory anotovány.

5.4 Klasifikace

Úlohu formulujeme jako hyperspektrální problém detekce pixelů. Cílem detektoru je najít hyperspektrální pixely, kde je přítomno cílové spektrum. Volba detekční metody je založena na předpokladu, že hledáme full-pixelové cíle.

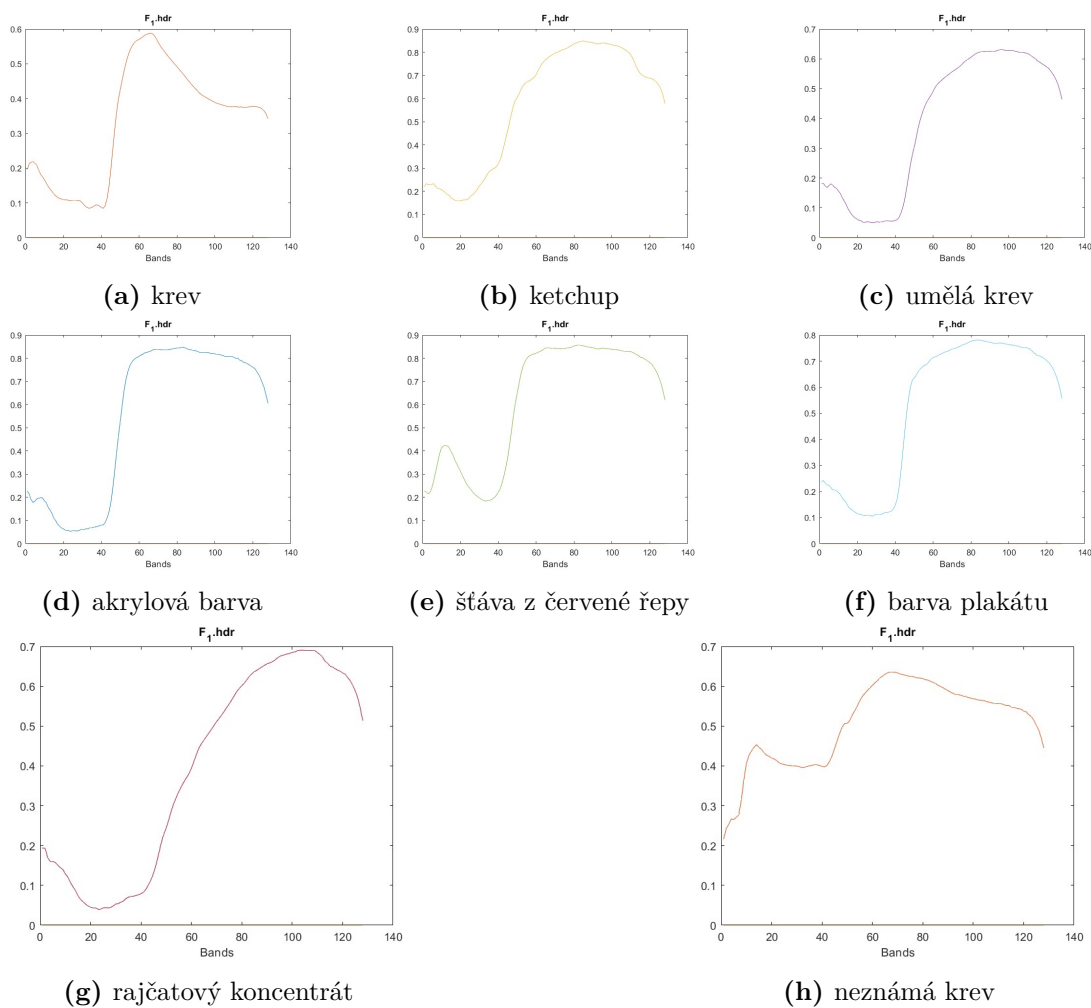
5.4.1 SVM

Support Vector Machines (SVM) jsou typem algoritmu strojového učení, který lze použít pro klasifikační nebo regresní úlohy. Cílem SVM je najít nadrovinu ve vysokorozměrném prostoru, který maximálně odděluje různé třídy.

Algoritmus SVM byl původně navržen pro konstrukci lineárního klasifikátoru. Alternativním využitím pro SVM je metoda jádra, která nám umožňuje zpracování lineárně neseparovatelných dat.


V případě klasifikace lineárně separovatelných dat najde algoritmus SVM nadrovinu, která rozděluje datové body do různých tříd. Nadrovinu je zvolena tak, aby maximálně oddělovala datové body různých tříd. Toho se dosáhne maximalizací vzdálenosti mezi nadrovinou a datovými body dvou tříd. Optimální nadrovinu můžeme definovat jako:

$$wx^T + b = 0 \quad (5.1)$$



Obrázek 5.2: Střední spektra reflektance získaná z obrázku F_1

kde w je vektor hmotnosti, x je vektor vstupního prvku, a b je zkreslení.



Obrázek 5.3: Lineární model SVM. Klasifikovaný lineárně separovatelná data.[55]

V případě regrese najde algoritmus SVM nadrovinu, která je co nejbližší datovým bodům.

Algoritmus SVM pro lineárně neseparovatelná data funguje tak, že nejprve transformuje data do vícerozměrného prostoru pomocí metody jádra (6.2), která mu umožňuje najít lineární separační hranici v transformovaném prostoru. SVM pak vybere několik datových bodů, nazývaných podpůrné vektory, které jsou nejbližší k hranici, a použije je k definování nadrovinu. Vzdálenost mezi nadrovinou a podpůrnými vektory je známá jako okraj. [55]

$$K(x, y) = \langle f(x), f(y) \rangle \quad (5.2)$$

SVM jsou výkonné, protože se dokážou naučit složité vztahy mezi datovými body, a to i v případech, kdy data nejsou lineárně oddělitelná v původním prostoru. Jsou také efektivní při práci s vysoko-rozměrnými daty, což z nich dělá oblíbenou volbu pro úlohy klasifikace textu a rozpoznávání obrázků.

Jedním z omezení SVM je, že mohou být citlivé na volbu funkce jádra a parametry modelu. Je také důležité škálovat data před trénováním SVM, protože vzdálenost mezi datovými body může být ovlivněna měřítkem funkcí. [56, 57]

Pro SVM trénovací sadu je náhodně vybráno 1% a 5% pixelů ze třídy 0 a 1-8 pomocí stratifikovaného náhodného vzorkování, takže existuje zhruba stejný počet (procento) pixelů z každé třídy. Ze confusion matrix (Obrázek 5.4) můžeme vypočítat přesnost:

$$AAC = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.3)$$

,kde TP (skutečně pozitivní) odkazuje na počet předpovědí, kde klasifikátor správně předpovídá pozitivní třídu jako pozitivní; TN (pravdivé negativní) je počet předpovědí, kde klasifikátor správně předpovídá negativní třídu jako negativní; FP (falešně pozitivní) je počet předpovědí, kde klasifikátor nesprávně předpovídá negativní třídu jako pozitivní a FN (falešně negativní) odkazuje na

0	3746777	26910	11684	9937	2266	5886	3400	5866	2767
1	20171	230495	1	128		6	5		1000
2	6383		70542	33		3	537	4	32
3	9254	36	38	50070		1	192	111	24
4	263			1	65080				
5	2255					52938			
6	5371		423	386			39885		
7	2298	1	1	168	4		61	53561	
8	14037	10308	32	59		12			3611
	0	1	2	3	4	5	6	7	8

Obrázek 5.4: Confusion matrix získaná pomocí algoritmu SVM. Confusion matrix je tabulka, která se používá k definování výkonu klasifikačního algoritmu. Vizualizuje a shrnuje výkon klasifikačního algoritmu. Má čtyři druhy výsledků diskutovaných výše (skutečně pozitivní, falešně negativní, falešně pozitivní a pravdivé negativní) spolu s pozitivní a negativní klasifikací.

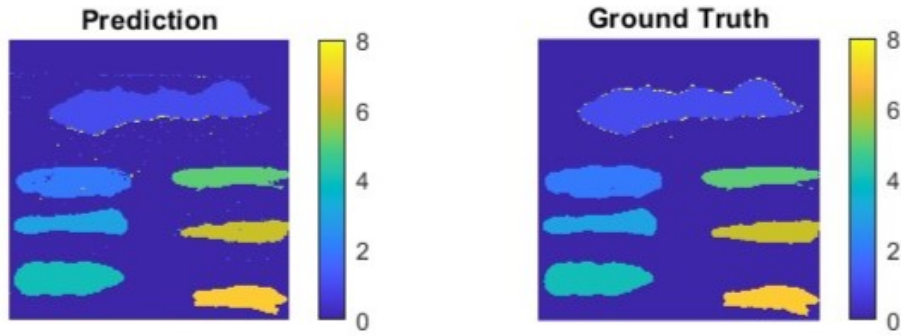
počet předpovědí, kde klasifikátor nesprávně předpovídá pozitivní třídu jako negativní. Vypočítaná hodnota přesnosti ověření je 93,6532 s chybou 0,0635 a přesnosti testování 93,5655 s chybou 0,0643.

SVM model se používá k predikci třídy každého pixelu v HS obrazu. Nakonec jsou předpovězené štítky uspořádány ve formátu 2D matice a zobrazeny spolu se skutečnými groundtruth obrázky.

5.4.2 Aplikace spektrálních metrik

Koncové členy, definované jako čisté signatury, lze použít ke specifikaci různých spektrálních tříd zájmu v datech, čímž poskytují klíčové informace při využívání hyperspektrálních dat. Technicky vzato je koncový člen obecně považován za kalibrovaný spektrální podpis v databázi nebo spektrální knihovně a nemusí být nutně skutečným vektorem vzorku dat. Pokud se koncový člen vyskytuje jako vektor vzorku reálných dat nebo pixelový vektor, označuje se jako vzorový vektor koncového prvku nebo pixelový vektor koncového prvku. Bohužel kvůli nevyhnutelným fyzikálním vlivům během získávání dat se často stává, že čisté vzorové vektory je téměř nemožné nalézt v reálném souboru dat a v takovém případě nelze ze souboru dat extrahovat žádné koncové členy. [58]

Koncové členy byly získány z hyperspektrálních dat. Koncové členy byly použity při spektrálním párování. Cílem bylo detekovat každou třídu pomocí všech čtyř metod, SID, SAM, SIDSAM a JMSAM.



Obrázek 5.5: Ground truth a předpověď získaná pomocí algoritmu SVM. Většina tříd byla v tomto scénáři správně označena, což vedlo k vysoké přesnosti klasifikace.

5.4.3 SID

SID, neboli metoda spektrálních metrik, je technika používaná k měření podobnosti mezi dvěma signály. Je založen na myšlence srovnání spektrálních vlastností dvou signálů, konkrétně na rozdílnosti mezi pravěpodobnostními distribucemi testovaného spektra t a referenčního spektra r o délce L .

Dále se SID vypočítá jako vzdálenost mezi dvěma spektrálními funkcemi pomocí metriky vzdálenosti, jako je Euklidovská vzdálenost nebo Kullback-Leiblerova divergence (5.6). Čím menší je vzdálenost mezi dvěma spektrálními funkcemi, tím větší je podobnost mezi oběma signály.

$$p_i = \frac{t_i}{\sum_{i=1}^L t_i} \quad (5.4)$$

$$q_i = \frac{r_i}{\sum_{i=1}^L r_i} \quad (5.5)$$

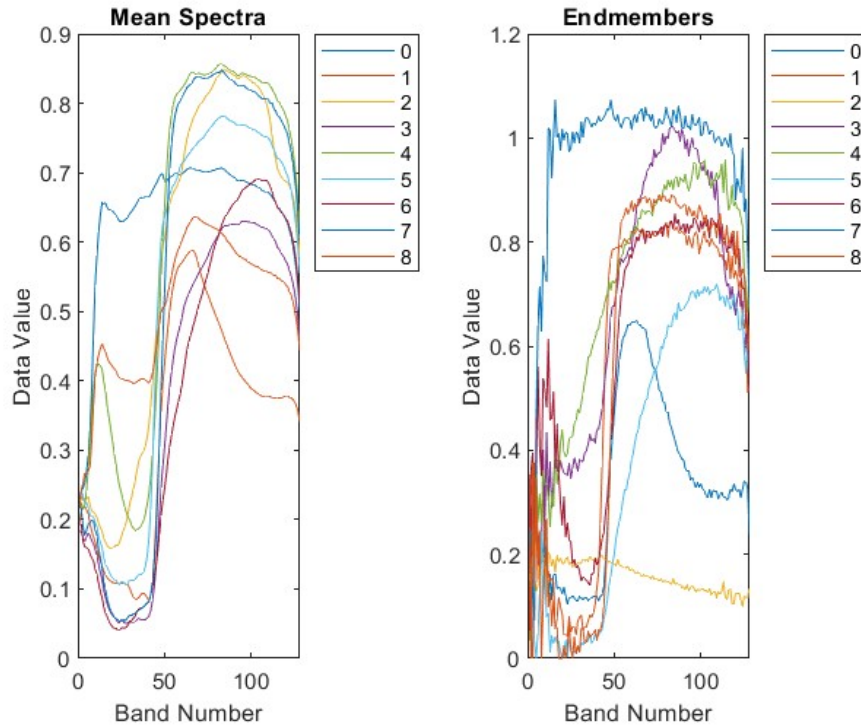
$$D(\mathbf{x} \parallel \mathbf{y}) = \sum_{i=1}^L p_i \log \left(\frac{p_i}{q_i} \right) \quad (5.6)$$

$$SID = \sum_{i=1}^L p_i \log \left(\frac{p_i}{q_i} \right) + \sum_{i=1}^L q_i \log \left(\frac{q_i}{p_i} \right) \quad (5.7)$$

SID se často používá k porovnání signálů, které nejsou přímo srovnatelné, jako jsou signály z různých senzorů nebo signály zaznamenané v různých časech. Může být také použit k detekci změn signálu v průběhu času, jako jsou změny ve spektrálních vlastnostech signálu v důsledku stárnutí nebo degradace.

Jedním omezením metody spektrální metriky je, že je citlivá na šum a další zkreslení signálu, což může ovlivnit přesnost měření. Je také omezena předpokladem, že spektrální vlastnosti signálů jsou reprezentativní pro jejich podobnost, což nemusí být vždy pravda. [59]

Koncové členy byly přiřazeny do náhodných tříd. Po implementaci metody SID je přítomen šumový artefakt. Důvod není znám. Pouze správně předpokládané třídy byly krev a rajčatový koncentrát.



Obrázek 5.6: Mean spectra a endmembers pro F_1 .

5.4.4 SAM

SAM, neboli spectral angle mapper, je založen na myšlence srovnání spektrálních vlastností dvou signálů, konkrétně výkonové spektrální hustoty (PSD) nebo Fourierovy transformace.

Pro výpočet SAM se nejprve vypočítá PSD nebo Fourierova transformace každého signálu. Fourierova transformace je reprezentace signálu ve frekvenční oblasti.

Dále se SAM vypočítá jako úhel mezi dvěma spektrálními funkcemi v komplexní rovině. Čím menší je úhel mezi dvěma spektrálními funkcemi, tím větší je podobnost mezi oběma signály.

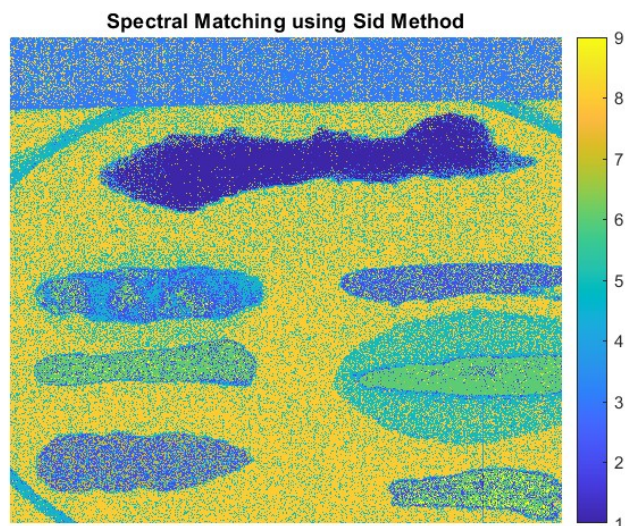
SAM určuje podobnost testovacího spektra t s referenčním spektrem r použitím následující rovnice:

$$SAM = \cos^{-1} \left(\frac{\vec{t} \cdot \vec{r}}{\|\vec{t}\| \cdot \|\vec{r}\|} \right) \quad (5.8)$$

$$SAM = \cos^{-1} \left(\frac{\sum_{i=1}^{nb} t_i r_i}{\sqrt{\sum_{i=1}^{nb} t_i^2} \sqrt{\sum_{i=1}^{nb} r_i^2}} \right) \quad (5.9)$$

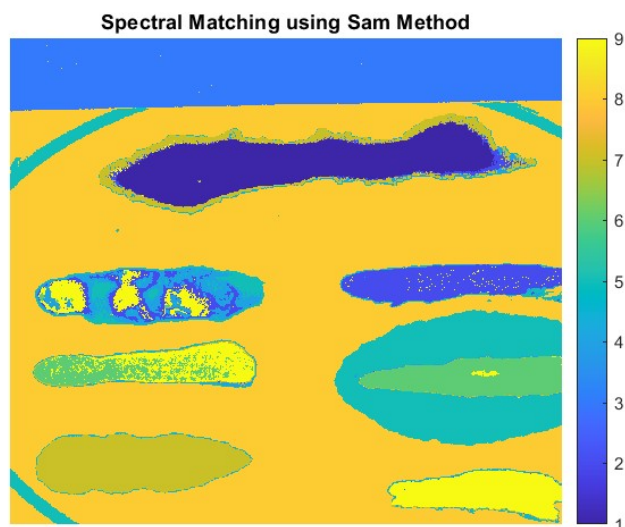
SAM se často používá k porovnání signálů, které nejsou přímo srovnatelné, jako jsou signály z různých senzorů nebo signály zaznamenané v různých časech. Může být také použit k detekci změn signálu v průběhu času, jako jsou změny ve spektrálních vlastnostech signálu v důsledku stárnutí nebo degradace.

Jedním omezením mapovače spektrálních úhlů je to, že je citlivý na šum a další zkreslení signálu, což může ovlivnit přesnost měření. Je také omezena předpokladem,



Obrázek 5.7: Predikce tříd pomocí spektrální metrické metody SID

že spektrální vlastnosti signálů jsou reprezentativní pro jejich podobnost, což nemusí být vždy pravda. [60]



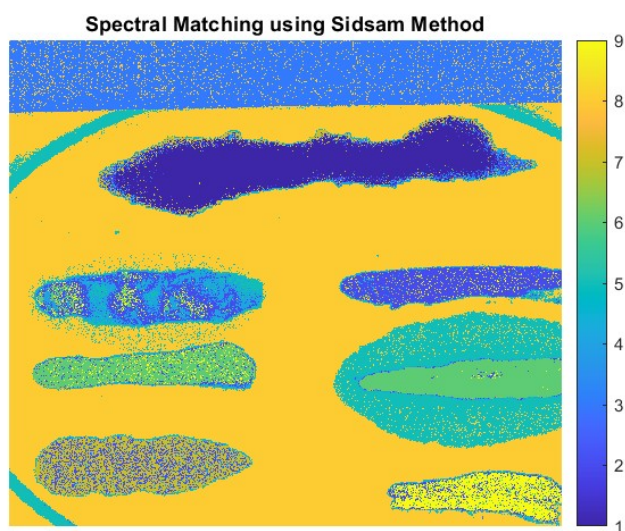
Obrázek 5.8: Predikce tříd pomocí spektrální metrické metody SAM

Výsledek (Obrázek 5.8) v SAM je o něco lepší. V implementaci SAM ve srovnání s SID neexistuje žádný artefakt. Přesto implementovaná metoda nedokáže rozlišit třídy. Vzorky, které jsou čisté, jsou zobrazeny jako směs několika tříd. Jedinými správně předpovězenými třídami však zůstávají 1 a 6.

5.4.5 SIDSAM

Po definování základních metrik spektrální podobnosti lze zavést kombinované hybridní metody. SIDSAM je kombinací dvou výše uvedených metod, SID a SAM. SIDSAM [61] lze vyjádřit jako:

$$SIDSAM = SID \times \tan SAM \quad (5.10)$$



Obrázek 5.9: Predikce tříd pomocí spektrální metrické metody SIDSAM.

Na stejném snímku HSI byla použita metoda SIDSAM, která je kombinací dvou výše uvedených metod, SID a SAM. Výsledek (Obrázek 5.9) ukazuje podobný šum jako SID, v menším množství.

5.4.6 JMSAM

JMSAM je technika hyperspektrálního párování, která integruje Jeffries-Matusita (JM) a algoritmus Spectral Angle Mapper (SAM). SAM a JM jsou ortogonálně promítnuty pomocí sinusových a tangensových funkcí pro zvýšení jejich spektrální schopnosti. JMSAM [62] pak lze vypočítat jako:

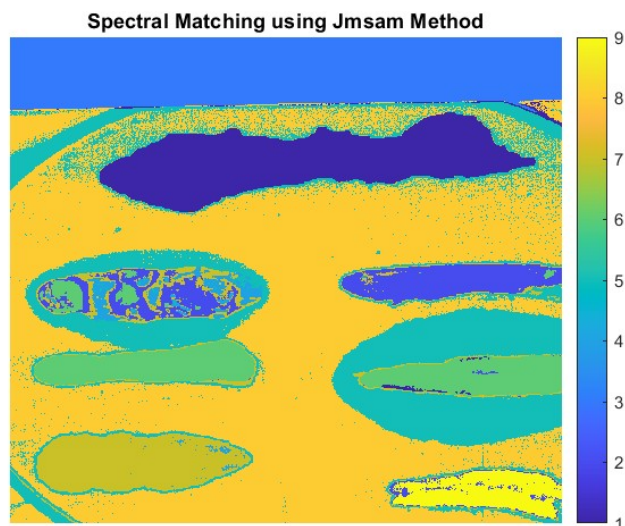
$$JMSAM = JM \times \tan SAM \quad (5.11)$$

Po implementaci JMSAM na stejném obrázku HSI byly získány podobné výsledky (Obrázek 5.10) jako u metody SAM (Obrázek 5.8). V některých částech má kečup stejnou spektrální odrazivost jako rajčatový koncentrát.

V této implementaci byla zpracována volně dostupná databáze. Vlastní získávání lékařských hyperspektrálních dat naráží na mnoho překážek, jako je chlazení vzorků, kontaminace, ochrana osobních údajů, komplikované získávání vzorků. Z důvodu složitosti získávání a uchování lékařských vzorků nebylo možné zaznamenat vlastní data v aktuálním stavu. Rozšiřující možnosti a aplikace kamery by se daly využít v další práci.

Podporované vektorové stroje (SVM) a metody spektrálních metrik jsou dva přístupy, které lze použít pro klasifikaci na úrovni pixelů v hyperspektrálním zobrazování (HSI). Oba přístupy mají své výhody a nevýhody a výběr mezi nimi bude záviset na konkrétních požadavcích aplikace.

Jedním z důvodů, proč mohou být SVM preferovány před metodami spektrální metriky pro detekci pixelů, je to, že dokážou zpracovat složitější data a



Obrázek 5.10: Predikce tříd pomocí spektrální metrické metody JMSAM.

jsou méně citlivé na šum. To se ukázalo v implementaci, porovnejte SVM (Obrázek 5.5) a SID (Obrázek 5.7). SVM jsou typem algoritmu strojového učení, který lze použít ke klasifikaci dat nalezením nadroviny, která maximálně odděluje různé třídy. To jim umožňuje zpracovávat složitá data a přesně klasifikovat pixely, i když je přítomen šum nebo jiné typy rušení. Zatímco používané metody spektrálních metrik jsou založeny na jednoduchém spektrálním párování. Použití SVM je velmi flexibilní, lze jej úspěšně použít jako klasifikátor v lineárně separovatelných a lineárně neseperovatelných datech.

Celkově, zatímco metody SVM i metody spektrální metriky mají své výhody a nevýhody, mohou být SVM preferovány pro detekci pixelů v HSI, pokud jsou přítomna složitá data nebo vysoká úroveň šumu, nebo když je nutné klasifikovat pixely na základě více funkcí. S dostatečným předzpracováním mohou tyto spektrální metrické metody přinést lepší výsledky.

Závěr

Technologie hyperspektrálního snímání prošla rychlým vývojem, pokud jde o hardware a systémy, a našla řadu aplikací v lékařské oblasti. Průzkum hyperspektrálního snímání v oblasti detekce, diagnostiky a monitorování nemocí může přinést nové pohledy do oblasti medicíny.

Tato bakalářská práce se zabývala využitím hyperspektrálního zobrazování v lékařských aplikacích.

V prvních kapitolách byl zmíněn teoretický úvod do problematiky, dále byl definován pojem multispektrální snímání a hyperspektrální snímání. Dále samotný princip hyperspektrálního zobrazování a různé metody získávání hyperspektrálních dat. Existují celkem čtyři způsoby zachycení těchto dat, včetně whiskbroom, pushbroom, staring a snapshot. Prezentovány byly také různé oblasti, ve kterých se hyperspektrální zobrazování používá.

Ve třetí kapitole byly představeny aplikace hyperspektrálního zobrazování v různých medicínských oborech. Díky svému neinvazivnímu přístupu byl široce používán v diagnostice onemocnění, zejména při detekci rakoviny. Může být také použit v chirurgickém vedení, jako pomoc chirurgům v reálném čase. Dále byly prezentovány veřejně dostupné soubory lékařských dat. Čtvrtá kapitola je věnována popisu částí hyperspektrálních systémů používaných v medicíně.

Konečně pátá kapitola zkoumá implementaci různých metod analýzy hyperspektrálních dat. V této práci byly implementovány SVM a spektrální metriky a výsledky byly porovnány. Získávání vlastních lékařských dat naráží na řadu překážek, jako je chlazení vzorků, kontaminace a ochrana osobních údajů. Pro tuto implementaci byla použita externě získaná data. V tomto jsme se pokusili detekovat různé třídy vzorků zobrazených na snímcích HSI. U kterých SVM vykazuje nejlepší výsledky.

Hyperspektrální zobrazování má světlou budoucnost, protože technologie se neustále vyvíjí a s tím se vyvíjejí nové aplikace. Byl zaveden jako standardní nástroj používaný v oblasti dálkového průzkumu Země a zajišťování kvality. HSI se již ukázal jako slibný nástroj pro neinvazivní lékařskou diagnostiku a monitorování a je pravděpodobné, že využití HSI v této oblasti bude nadále růst.

Bibliografie

1. M. BORN, E. Wolf. Principles of Optics. *Cambridge University Press*. 1997. Dostupné také z: https://books.google.cz/books?hl=de&lr=&id=HY-GDAAAQBAJ & oi = fnd & pg = PP1 & ots = 4t7jv6oEKB & sig = xtmvEjONZBHd9gDFcGM8N0xHaUA&redir_esc=y#v=onepage&q&f=false.
2. NASA.GOV. Electromagnetic Spectrum. 2013. Dostupné také z: <https://imagine.gsfc.nasa.gov/science/toolbox/emspectrum2.html>.
3. SWIN.EDU.AU. Spectroscopy. *COSMOS*. 2022. Dostupné také z: <https://astronomy.swin.edu.au/cosmos/s/Spectroscopy>.
4. PHYSICSCCLASSROOM.COM. Physics Tutorial: Dispersion of Light by Prisms. 2021. Dostupné také z: <https://www.physicsclassroom.com/class/refrn/Lesson-4/Dispersion-of-Light-by-Prisms#:~:text=The%20separation%20of%20visible%20light,upon%20passage%20through%20a%20prism>.
5. PASCHOTTA, Dr. Rüdiger. Diffraction. *RP Photonics Encyclopedia*. 2022. Dostupné také z: <https://www.rp-photonics.com/diffraction.html>.
6. WAIKATO THE UNIVERSITY OF, Waikato Te Whare Wānanga o. Refraction of light. *Science Learning Hub*. 2012. Dostupné také z: <https://www.sciencelearn.org.nz/resources/49-refraction-of-light>.
7. LU, G.; FEI, B. Medical hyperspectral imaging: a review. *Journal of Biomedical Optics*. 2014. Dostupné také z: <https://www.spiedigitallibrary.org/journals/journal-of-biomedical-optics/volume-19/issue-01/010901/Medical-hyperspectral-imaging-a-review/10.1117/1.JBO.19.1.010901.full?SSO=1&tab=ArticleLinkCited>.
8. QIN, Jianwei; CHAO, Kuanglin; KIM, Moon S.; LU, Renfu; BURKS, Thomas F. Hyperspectral and multispectral imaging for evaluating food safety and quality. *Journal of Food Engineering*. 2013, roč. 118, č. 2, s. 157–171. ISSN 0260-8774. Dostupné z DOI: <https://doi.org/10.1016/j.jfoodeng.2013.04.001>.
9. KHAN, Muhammad Jaleed; KHAN, Hamid Saeed; YOUSAF, Adeel; KHURSHID, Khurram; ABBAS, Asad. Modern Trends in Hyperspectral Image Analysis: A Review. *IEEE Access*. 2018, roč. 6, s. 14118–14129. Dostupné z DOI: [10.1109/ACCESS.2018.2812999](https://doi.org/10.1109/ACCESS.2018.2812999).
10. SARIĆ, Rijad; NGUYEN, Viet D.; BURGE, Timothy; BERKOWITZ, Oliver; TRTÍLEK, Martin; WHELAN, James; LEWSEY, Mathew G.; ČUSTOVIĆ, Edhem. Applications of hyperspectral imaging in plant phenotyping. *Trends in Plant Science*. 2022. ISSN 1360-1385. Dostupné z DOI: <https://doi.org/10.1016/j.tplants.2021.12.003>.

11. CLANCY, Neil T.; JONES, Geoffrey; MAIER-HEIN, Lena; ELSON, Daniel S.; STOYANOV, Danail. Surgical spectral imaging. *Medical Image Analysis*. 2020, roč. 63, s. 101699. ISSN 1361-8415. Dostupné z DOI: <https://doi.org/10.1016/j.media.2020.101699>.
12. LI, Qingli; HE, Xiaofu; WANG, Yiting; LIU, Hongying; XU, Dongrong; GUO, Fangmin. Review of spectral imaging technology in biomedical engineering: achievements and challenges. *Journal of biomedical optics*. 2013, roč. 18, č. 10, s. 100901–100901. Dostupné z DOI: [10.1117/1.jbo.18.10.100901](https://doi.org/10.1117/1.jbo.18.10.100901).
13. HUETE, A.R. 11 - REMOTE SENSING FOR ENVIRONMENTAL MONITORING. In: ARTIOLA, Janick F.; PEPPER, Ian L.; BRUSSEAU, Mark L. (ed.). *Environmental Monitoring and Characterization*. Burlington: Academic Press, 2004, s. 183–206. ISBN 978-0-12-064477-3. Dostupné z DOI: <https://doi.org/10.1016/B978-012064477-3/50013-8>.
14. HAPKE, Bruce. Reflectance Methods and Applications. In: LINDON, John C.; TRANTER, George E.; KOPPENAAL, David W. (ed.). *Encyclopedia of Spectroscopy and Spectrometry (Third Edition)*. Third Edition. Oxford: Academic Press, 2017, s. 931–935. ISBN 978-0-12-803224-4. Dostupné z DOI: <https://doi.org/10.1016/B978-0-12-803224-4.00019-4>.
15. ZHOU, Xin; ZHAO, Chunjiang; SUN, Jun; YAO, Kunshan; XU, Min. Detection of lead content in oilseed rape leaves and roots based on deep transfer learning and hyperspectral imaging technology. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*. 2022, s. 122288. ISSN 1386-1425. Dostupné z DOI: <https://doi.org/10.1016/j.saa.2022.122288>.
16. KHAN, Atiya; VIBHUTE, Amol D.; MALI, Shankar; PATIL, C.H. A systematic review on hyperspectral imaging technology with a machine and deep learning methodology for agricultural applications. *Ecological Informatics*. 2022, roč. 69, s. 101678. ISSN 1574-9541. Dostupné z DOI: <https://doi.org/10.1016/j.ecoinf.2022.101678>.
17. HONG, Guan; ABD EL-HAMID, Hazem T. Hyperspectral imaging using multivariate analysis for simulation and prediction of agricultural crops in Ningxia, China. *Computers and Electronics in Agriculture*. 2020, roč. 172, s. 105355. ISSN 0168-1699. Dostupné z DOI: <https://doi.org/10.1016/j.compag.2020.105355>.
18. WIEME, Jana; MOLLAZADE, Kaveh; MALOUNAS, Ioannis; ZUDE-SASSE, Manuela; ZHAO, Ming; GOWEN, Aoife; ARGYROPOULOS, Dimitrios; FOUNTAS, Spyros; VAN BEEK, Jonathan. Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review. *Biosystems Engineering*. 2022, roč. 222, s. 156–176. ISSN 1537-5110. Dostupné z DOI: <https://doi.org/10.1016/j.biosystemseng.2022.07.013>.
19. ÖZDOĞAN, Gözde; LIN, Xiaohui; SUN, Da-Wen. Rapid and noninvasive sensory analyses of food products by hyperspectral imaging: Recent application developments. *Trends in Food Science and Technology*. 2021, roč. 111, s. 151–165. ISSN 0924-2244. Dostupné z DOI: <https://doi.org/10.1016/j.tifs.2021.02.044>.

20. WU, Di; SUN, Da-Wen. Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review — Part I: Fundamentals. *Innovative Food Science and Emerging Technologies*. 2013, roč. 19, s. 1–14. ISSN 1466-8564. Dostupné z DOI: <https://doi.org/10.1016/j.ifset.2013.04.014>.
21. MANOLAKIS, Dimitris; TRUSLOW, Eric; PIEPER, Michael; COOLEY, Thomas; BRUEGGEMAN, Michael. Detection Algorithms in Hyperspectral Imaging Systems: An Overview of Practical Algorithms. *IEEE Signal Processing Magazine*. 2014, roč. 31, č. 1, s. 24–33. Dostupné z DOI: [10.1109/MSP.2013.2278915](https://doi.org/10.1109/MSP.2013.2278915).
22. AKBARI, Hamed; UTO, Kuniaki; KOSUGI, Yukio; KOJIMA, Kazuyuki; TANAKA, Naofumi. Cancer detection using infrared hyperspectral imaging. *Cancer Science*. 2011, roč. 102, č. 4, s. 852–857. Dostupné z DOI: <https://doi.org/10.1111/j.1349-7006.2011.01849.x>.
23. GOTO, Atsushi; NISHIKAWA, Jun; KIYOTOKI, Shu; NAKAMURA, Munetaka; NISHIMURA, Junichi; OKAMOTO, Takeshi; OGIHARA, Hiroyuki; FUJITA, Yusuke; HAMAMOTO, Yoshihiko; SAKAIDA, Isao. Use of hyperspectral imaging technology to develop a diagnostic support system for gastric cancer. *Journal of Biomedical Optics*. 2015, roč. 20, č. 1, s. 016017. Dostupné z DOI: [10.1117/1.JBO.20.1.016017](https://doi.org/10.1117/1.JBO.20.1.016017).
24. ABOUGHALEB, Ibrahim H; AREF, Mohamed Hisham; EL-SHARKAWY, Yasser H. Hyperspectral imaging for diagnosis and detection of ex-vivo breast cancer. *Photodiagnosis and Photodynamic Therapy*. 2020, roč. 31, s. 101922.
25. AKBARI, Hamed; HALIG, Luma; SCHUSTER, David M.; FEI, Baowei; OSUNKOYA, Adeboye; MASTER, Viraj; NIEH, Peter; CHEN, Georgia. Hyperspectral imaging and quantitative analysis for prostate cancer detection. *Journal of Biomedical Optics*. 2012, roč. 17, č. 7, s. 076005. Dostupné z DOI: [10.1117/1.JBO.17.7.076005](https://doi.org/10.1117/1.JBO.17.7.076005).
26. MAROTZ, Jörg; SCHULZ, Torsten; SEIDER, Sebastian; CRUZ, Diogo; ALJOWDER, Ahmed; PROMNY, Dominik; DAESCHLEIN, Georg; WILD, Thomas; SIEMERS, Frank. 3D-perfusion analysis of burn wounds using hyperspectral imaging. *Burns*. 2021, roč. 47, č. 1, s. 157–170. ISSN 0305-4179. Dostupné z DOI: <https://doi.org/10.1016/j.burns.2020.06.001>.
27. KHAODHIAR, Lalita; DINH, Thanh; SCHOMACKER, Kevin T.; PANASYUK, Svetlana V.; FREEMAN, Jenny E.; LEW, Robert; VO, Tiffany; PANASYUK, Alexander A.; LIMA, Christina; GIURINI, John M.; LYONS, Thomas E.; VEVES, Aristidis. The Use of Medical Hyperspectral Technology to Evaluate Microcirculatory Changes in Diabetic Foot Ulcers and to Predict Clinical Outcomes. *Diabetes Care*. 2007, roč. 30, č. 4, s. 903–910. ISSN 0149-5992. Dostupné z DOI: [10.2337/dc06-2209](https://doi.org/10.2337/dc06-2209).

28. ZHERDEVA, Larisa A.; BRATCHENKO, Ivan A.; MYAKININ, Oleg O.; MORYATOV, Alexander A.; KOZLOV, Sergey V.; ZAKHAROV, Valery P. In vivo hyperspectral imaging and differentiation of skin cancer. In: LUO, Qingming; LI, Xingde; GU, Ying; TANG, Yuguo (ed.). *Optics in Health Care and Biomedical Optics VII*. SPIE, 2016, sv. 10024, 100244G. Dostupné z DOI: [10.1117/12.2246433](https://doi.org/10.1117/12.2246433).
29. SWIFT, Luther M.; ASFOUR, Huda; MUSELIMYAN, Narine; LARSON, Cinnamon; ARMSTRONG, Kenneth; SARVAZYAN, Narine A. Hyperspectral imaging for label-free invivo identification of myocardial scars and sites of radiofrequency ablation lesions. *Heart Rhythm*. 2018, roč. 15, č. 4, s. 564–575. ISSN 1547-5271. Dostupné z DOI: <https://doi.org/10.1016/j.hrthm.2017.12.014>.
30. CHIN, J. A.; WANG, E. C.; KIBBE, M. R. Evaluation of hyperspectral technology for assessing the presence and severity of peripheral artery disease. In: 2011, sv. 54. Č. 6. ISSN 1679–1688. Dostupné z DOI: <https://doi.org/10.1016/j.jvs.2011.06.022>.
31. GAO, Liang; SMITH, R. Theodore; TKACZYK, Tomasz S. Snapshot hyperspectral retinal camera with the Image Mapping Spectrometer (IMS). *Biomed. Opt. Express*. 2012, roč. 3, č. 1, s. 48–54. Dostupné z DOI: [10.1364/BOE.3.000048](https://doi.org/10.1364/BOE.3.000048).
32. NOURRIT, V.; DENNISS, J.; MUQIT, M.M.K.; SCHIESSL, I.; FENERTY, C.; STANGA, P.E.; HENSON, D.B. High-resolution hyperspectral imaging of the retina with a modified fundus camera. *Journal Français d’Ophtalmologie*. 2010, roč. 33, č. 10, s. 686–692. ISSN 0181-5512. Dostupné z DOI: <https://doi.org/10.1016/j.jfo.2010.10.010>.
33. BANKMAN, Isaac. *Handbook of medical image processing and analysis*. Elsevier, 2008.
34. HALICEK, Martin; FABELO, Himar; ORTEGA, Samuel; CALLICO, Gustavo M.; FEI, Baowei. In-Vivo and Ex-Vivo Tissue Analysis through Hyperspectral Imaging Techniques: Revealing the Invisible Features of Cancer. *Cancers*. 2019, roč. 11, č. 6. ISSN 2072-6694. Dostupné z DOI: [10.3390/cancers11060756](https://doi.org/10.3390/cancers11060756).
35. FABELO, Himar; ORTEGA, Samuel; SZOLNA, Adam; BULTERS, Diederik; PIÑEIRO, Juan F.; KABWAMA, Silvester; J-O’SHANAHAN, Aruma; BULSTRODE, Harry; BISSHOPP, Sara; KIRAN, B. Ravi; RAVI, Daniele; LAZCANO, Raquel; MADROÑAL, Daniel; SOSA, Coralia; ESPINO, Carlos; MARQUEZ, Mariano; DE LA LUZ PLAZA, María; CAMACHO, Rafael; CARRERA, David; HERNÁNDEZ, María; CALLICÓ, Gustavo M.; MORERA MOLINA, Jesús; STANCIULESCU, Bogdan; YANG, Guang-Zhong; SALVADOR, Rubén; JUÁREZ, Eduardo; SANZ, César; SARMIENTO, Roberto. In-Vivo Hyperspectral Human Brain Image Database for Brain Cancer Detection. *IEEE Access*. 2019, roč. 7, s. 39098–39116. Dostupné z DOI: [10.1109/ACCESS.2019.2904788](https://doi.org/10.1109/ACCESS.2019.2904788).
36. ZHANG, Ying; WANG, Yan; ZHANG, Benyan; LI, Qingli. A hyperspectral dataset of precancerous lesions in gastric cancer and benchmarks for pathological diagnosis. *Journal of Biophotonics*. 2022, roč. 15, č. 11, e202200163. Dostupné z DOI: <https://doi.org/10.1002/jbio.202200163>.

37. ZHANG, Qing; LI, Qingli; YU, Guanzhen; SUN, Li; ZHOU, Mei; CHU, Junhao. A Multidimensional Choledoch Database and Benchmarks for Cholangiocarcinoma Diagnosis. *IEEE Access*. 2019, roč. 7, s. 149414–149421. Dostupné z DOI: [10.1109/ACCESS.2019.2947470](https://doi.org/10.1109/ACCESS.2019.2947470).
38. QIN, Jianwei. CHAPTER 5 - Hyperspectral Imaging Instruments. In: SUN, Da-Wen (ed.). *Hyperspectral Imaging for Food Quality Analysis and Control*. San Diego: Academic Press, 2010, s. 129–172. ISBN 978-0-12-374753-2. Dostupné z DOI: <https://doi.org/10.1016/B978-0-12-374753-2.10005-X>.
39. CHENG, Jun-Hu; SUN, Da-Wen. Hyperspectral imaging as an effective tool for quality analysis and control of fish and other seafoods: Current research and potential applications. *Trends in Food Science and Technology*. 2014, roč. 37, č. 2, s. 78–91. ISSN 0924-2244. Dostupné z DOI: <https://doi.org/10.1016/j.tifs.2014.03.006>.
40. AMIGO, José Manuel. Practical issues of hyperspectral imaging analysis of solid dosage forms. 2010, roč. 398(1), s. 93–109. Dostupné z DOI: <https://doi.org/10.1007/s00216-010-3828-z>.
41. MINION, Jessica; SOHN, Hojoon; PAI, Madhukar. Light-emitting diode technologies for TB diagnosis: what is on the market? *Expert Review of Medical Devices*. 2009, roč. 6, č. 4, s. 341–345. Dostupné z DOI: [10.1586/erd.09.26](https://doi.org/10.1586/erd.09.26).
42. REIFEGERSTE, Frank; LIENIG, Jens. Modelling of the Temperature and Current Dependence of LED Spectra. *Journal of Light and Visual Environment*. 2008, roč. 32, č. 3, s. 288–294. Dostupné z DOI: [10.2150/jlve.32.288](https://doi.org/10.2150/jlve.32.288).
43. SCHUBERT, E. Fred. *Light-Emitting Diodes*. 2. vyd. Cambridge University Press, 2006. Dostupné z DOI: [10.1017/CB09780511790546](https://doi.org/10.1017/CB09780511790546).
44. ANDO, Jun; PALONPON, Almar F; SODEOKA, Mikiko; FUJITA, Katsumasa. High-speed Raman imaging of cellular processes. *Current Opinion in Chemical Biology*. 2016, roč. 33, s. 16–24. ISSN 1367-5931. Dostupné z DOI: <https://doi.org/10.1016/j.cbpa.2016.04.005>. Chemical genetics and epigenetics * Molecular imaging.
45. CAMP, Charles H. Jr; LEE, Young Jong; HARTSHORN, John M. Heddleston; Christopher M.; WALKER, Angela R. Hight; RICH, Jeremy N.; LATHIA, Justin D.; CICERONE, Marcus T. High-speed coherent Raman fingerprint imaging of biological tissues. *Nature Photonics 2014-jul 20 vol. 8 iss. 8*. 2014, roč. 8. Dostupné z DOI: [10.1038/nphoton.2014.145](https://doi.org/10.1038/nphoton.2014.145).
46. HOHMAN, Becky. LED Light Source: Major Advance in Fluorescence Microscopy. *Biomedical Instrumentation and Technology*. 2007, roč. 41, č. 6, s. 461–464. ISSN 0899-8205. Dostupné z DOI: [10.2345/0899-8205\(2007\)41\[461:LLSMAI\]2.0.CO;2](https://doi.org/10.2345/0899-8205(2007)41[461:LLSMAI]2.0.CO;2).
47. AMIGO, Jose Manuel. *Hyperspectral imaging*. Elsevier, 2019.
48. GAT, Nahum. Imaging spectroscopy using tunable filters: a review. In: SZU, Harold H.; VETTERLI, Martin; CAMPBELL, William J.; BUSS, James R. (ed.). *Wavelet Applications VII*. SPIE, 2000, sv. 4056, s. 50–64. Dostupné z DOI: [10.1117/12.381686](https://doi.org/10.1117/12.381686).

49. FAVREAU, Peter F.; HERNANDEZ, Clarissa; LINDSEY, Ashley Stringfellow; ALVAREZ, Diego F.; RICH, Thomas C.; PRABHAT, Prashant; LEAVESLEY, Silas J. Thin-film tunable filters for hyperspectral fluorescence microscopy. *Journal of Biomedical Optics*. 2013, roč. 19, č. 1, s. 1–11. Dostupné z DOI: 10.1117/1.JBO.19.1.011017.
50. FASTIE, William G. A Small Plane Grating Monochromator. *J. Opt. Soc. Am.* 1952, roč. 42, č. 9, s. 641–647. Dostupné z DOI: 10.1364/JOSA.42.000641.
51. GILBERT, A.S. Vibrational, Rotational and Raman Spectroscopy, Historical Perspective. In: LINDON, John C.; TRANTER, George E.; KOPPENAAL, David W. (ed.). *Encyclopedia of Spectroscopy and Spectrometry (Third Edition)*. Third Edition. Oxford: Academic Press, 2017, s. 600–609. ISBN 978-0-12-803224-4. Dostupné z DOI: <https://doi.org/10.1016/B978-0-12-803224-4.00308-3>.
52. YANG, Chenghai; EVERITT, James H.; DAVIS, Michael R.; MAO, Chengye. A CCD Camera-based Hyperspectral Imaging System for Stationary and Airborne Applications. *Geocarto International*. 2003, roč. 18, č. 2, s. 71–80. Dostupné z DOI: 10.1080/10106040308542274.
53. ROMASZEWSKI, Michał; GŁOMB, Przemysław; SOCHAN, Arkadiusz; CHOLEWA, Michał. *A Dataset for Evaluating Blood Detection in Hyperspectral Images*. 2020. Dostupné z arXiv: 2008.10254 [cs.CV]. arXiv preprint arXiv:2008.10254.
54. CHANG, Chein-I. *Hyperspectral data processing: algorithm design and analysis*. John Wiley & Sons, 2013.
55. HUANG, SHUJUN; CAI, NIANGUANG; PACHECO, PEDRO PENZUTI; NARRANDES, SHAVIRA; WANG, YANG; XU, WAYNE. Applications of Support Vector Machine (SVM) Learning in Cancer Genomics. *Cancer Genomics & Proteomics*. 2018, roč. 15, č. 1, s. 41–51. ISSN 1109-6535. Dostupné z eprint: <https://cgp.iiarjournals.org/content/15/1/41.full.pdf>.
56. HEARST, Marti; DUMAIS, S.T.; OSMAN, E.; PLATT, John; SCHOLKOPF, B. Support vector machines. *Intelligent Systems and their Applications, IEEE*. 1998, roč. 13, s. 18–28. Dostupné z DOI: 10.1109/5254.708428.
57. KOPROWSKI, Robert. *Processing of Hyperspectral Medical Images*. 2017.
58. CHANG, Chein-I. Real-Time Progressive Hyperspectral Image Processing. In: 2016.
59. CHANG, Chein-I. An information-theoretic approach to spectral variability, similarity, and discrimination for hyperspectral image analysis. *IEEE Transactions on Information Theory*. 2000, roč. 46, č. 5, s. 1927–1932. Dostupné z DOI: 10.1109/18.857802.
60. KRUSE, F.A.; LEFKOFF, A.B.; BOARDMAN, J.W.; HEIDEBRECHT, K.B.; SHAPIRO, A.T.; BARLOON, P.J.; GOETZ, A.F.H. The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*. 1993, roč. 44, č. 2, s. 145–163. ISSN 0034-4257. Dostupné z DOI: [https://doi.org/10.1016/0034-4257\(93\)90013-N](https://doi.org/10.1016/0034-4257(93)90013-N). Airbone Imaging Spectrometry.

61. KRAUZ, Lukáš; PATA, Petr; KAISER, Jan. Assessing the Spectral Characteristics of Dye- and Pigment-Based Inkjet Prints by VNIR Hyperspectral Imaging. *Sensors*. 2022, roč. 22, s. 603. Dostupné z DOI: 10.3390/s22020603.
62. PADMA, S.; SANJEEVI, S. Jeffries Matusita based mixed-measure for improved spectral matching in hyperspectral image analysis. *International Journal of Applied Earth Observation and Geoinformation*. 2014, roč. 32, s. 138–151. ISSN 1569-8432. Dostupné z DOI: <https://doi.org/10.1016/j.jag.2014.04.001>.

Přílohy

A Metriky

Obsahuje výstupní soubory obrázků, na které byly aplikovány spektrální metriky.

- A_1
- jmsam1.jpg
- sidsam1.jpg
- sid1.jpg
- sam+.jpg
- D_1
- jmsam4.jpg
- endmembers4.jpg
- sidam4.jpg
- sid4.jpg
- sam4.jpg
- E_7
- jmsam6.jpg
- sidam6.jpg
- sid6.jpg
- sam6.jpg
- E_{2_1}
- jmsam7.jpg
- sidam7.jpg
- sid7.jpg
- sam7.jpg
- endmembers7.jpg

B SVM

Obsahuje výstupní soubory klasifikačního algoritmu SVM.

- A_1 .fig
- B_1 .fig
- C_1 .fig
- Confusion matrix.jpg
- D_1 .fig
- E_1 .fig
- E_7 .fig
- E_21 .fig
- F_1a .fig
- F_1s .fig
- F_2 .fig
- F_2k .fig
- F_7 .fig
- F_21 .fig