


České vysoké učení technické v Praze
FAKULTA ELEKTROTECHNICKÁ

Katedra teorie obvodů



BAKALÁŘSKÁ PRÁCE

**Využití hyperspektrálního snímání pro
analýzu biologických vzorků**

**Hyperspectral imaging exploitation for
biological sample analysis**

Vypracovala: Eliška Nejedlá
Vedoucí práce: Ing. Lukáš Krauz
Studijní program: Lékařská elektronika a bioinformatika
Rok: 2022

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Nejedlá** Jméno: **Eliška** Osobní číslo: **495638**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávací katedra/ústav: **Katedra teorie obvodů**
Studijní program: **Lékařská elektronika a bioinformatika**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Využití hyperspektrálního snímání pro analýzu biologických vzorků

Název bakalářské práce anglicky:

Hyperspectral imaging exploitation for biological sample analysis

Pokyny pro vypracování:

Seznamte se s principy hyperspektrálního snímání. Zaměřte se především na algoritmy a přístupy, které jsou využívány pro hyperspektrální snímání biologických vzorků. Na základě odborné literatury podejte přehled aktuálních biologických aplikací, kde je hyperspektrální snímání využíváno. Seznamte se s parametry a vlastnostmi hyperspektrální kamery Specim PFD4K-65-V10E. Navrhněte sadu biologických vzorků, vhodných pro snímání uvedeným laboratorním hyperspektrálním systémem a následně připravte datový set. Po dohodě s vedoucím na vytvořeném datasetu ve vhodném programovém prostředí otestujte vybrané algoritmy používané k analýze biologických hyperspektrálních dat.

Seznam doporučené literatury:

- [1] Amigo, J.M., (2019). Hyperspectral imaging. Elsevier.
- [2] Basantia, N. C., Nollet, L. M., Kamruzzaman, M. (Eds.). (2018). Hyperspectral Imaging Analysis and Applications for Food Quality. CRC Press.
- [3] Chang, C. I. (2013). Hyperspectral data processing: algorithm design and analysis. John Wiley & Sons.
- [4] Vadivambal, R.; Jayas, D. S. (2015). Bio-imaging: principles, techniques, and applications. CRC Press.
- [5] 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: **20.05.2022**

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

.....
Eliška Nejedlá

Poděkování

Děkuji vedoucímu práce Ing. Lukáši Krauzovi za neocenitelné rady a pomoc při tvorbě bakalářské práce. Dále děkuji Bc. Janě Vaněčkové za velmi podnětné rady v oblasti anatomie.

Eliška Nejedlá

Název práce:

Využití hyperspektrálního snímání pro analýzu biologických vzorků

Autor: Eliška Nejedlá

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 přehledem využití hyperspektrálního snímání v oblasti biologie. Teoretická část práce je zaměřena na základní principy hyperspektrálního snímání, algoritmy analýzy hyperspektrálních dat a aktuální využití hyperspektrálního snímání v biologických aplikacích. V praktické části práce byla popsána hyperspektrální kamera, se kterou byly následně nasnímány biologické vzorky a byl z nich vytvořen datový set. Na vybraná data byly aplikovány spektrální metriky v aplikaci HyperCalib v prostředí MATLAB nebo algoritmy v programu perClass Mira.

Klíčová slova: Hyperspektrální snímání, analýza dat, spektrální metriky, aplikace hyperspektrálního snímání, biologické vzorky, analýza biologických vzorků

Title:

Hyperspectral imaging exploitation for biological sample analysis

Author: Eliška Nejedlá

Abstract:

The bachelor thesis deals with the use of hyperspectral sensing in the field of biology. The theoretical part of the thesis is focused on the basic principles of hyperspectral sensing, algorithms for analysis of hyperspectral data, and the current use of hyperspectral sensing in biological applications. In the practical part of the thesis, a hyperspectral camera was described, by which biological samples were subsequently taken and a data file was created from them. Spectral metrics in HyperCalib in MATLAB or algorithms in perClass Mira were applied to selected data.

Key words: Hyperspectral Imaging, data analysis, spectral metrics, application of hyperspectral imaging, biological samples, analysis of biological samples

Obsah

Seznam použitých zkratk	xi
Seznam obrázků	xiii
Seznam tabulek	xiv
Úvod	1
1 Parametry světla	3
1.1 Šíření světla	3
1.2 Elektromagnetické záření	4
1.3 Elektromagnetické spektrum	5
2 Lidský zrakový systém	7
2.1 Optická soustava	7
2.2 Lidské oko	9
2.2.1 Světlolomný systém	9
2.2.2 Světločivný systém	10
2.2.3 Vnitřek bulbus oculi	10
2.2.4 Přidatné orgány	11
3 Hyperspektrální snímání	13
3.1 Metody snímání	15
3.1.1 Whisk-broom	15
3.1.2 Push-broom	15
3.1.3 Staring	16
3.1.4 Snapshot	16
3.2 Analýza hyperspektrálních dat	17
3.2.1 SID	17
3.2.2 SAM	18
3.2.3 SIDSAM	18
3.2.4 SVM	18
3.2.5 PCA	19
4 Aplikace HSI	21
4.1 Zemědělství	22
4.2 Medicína	23
4.2.1 Detekce	23
4.2.2 Operace	25
4.3 Potraviny	25
4.3.1 Maso	26
4.3.2 Ryby	28
4.3.3 Ovoce a zelenina	29

5	Analýza nasnímaných dat	31
5.1	Hyperspektrální soustava	31
5.1.1	Hyperspektrální kamera Specim PFD4K-65-V10E	31
5.1.2	Laboratorní skener Specim LabScanner 40x20	33
5.2	Postup snímání a vyhodnocení	35
5.3	Nasnímané vzorky	37
5.3.1	Mleté maso	37
5.3.2	Rostliny	41
5.3.3	Potraviny	43
	Závěr	45
	Bibliografie	47
	Přílohy	51
A	První příloha	51
A.1	mletemaso_2022-04-19_09-28-31	51
A.2	MATLAB	51
A.3	Vyhodnoceni_metrik	52

Seznam použitých zkratek

2D Dvou dimenzionální (*Two-Dimensional*)

3D Tří dimenzionální (*Three-Dimensional*)

AIS Vzduchový zobrazovací spektrometr (*Airbone Imaging Spectrometer*)

ALI Advanced Land Imager

AVIRIS Airborne Visible/Infrared Imaging Spectrometer

BIL *Band-Interleaved-by-Line*

BIP *Band-Interleaved-by-Pixel*

BSQ *Band-Sequential*

ČVUT České vysoké učení technické

DCI Derivátový chlorofylový index (*Derivative Chlorophyll Index*)

GPS Globální polohový systém (*Global Positioning System*)

GTR *Ground Truth Radiometer*

HSI Hyperspektrální snímání (*Hyperspectral Imaging*)

HVS Zrakový systém člověka (*Human Vision System*)

IR Infračervené (*Infrared*)

LAI Index listové plochy (*Leaf Area Index*)

LCTF Laditelné filtry z tekutých krystalů (*Liquid Crystal Tunable Filters*)

LED Elektroluminiscenční dioda (*Light-Emitting Diode*)

LS-SVM *Least-Square Support Vector Machines*

LVF Lineárně proměnné filtry (*Linear Variable Filters*)

LWIR Dlouhovlnné infračervené pásmo (*Long-Wave Infrared Region*)

MCARI Modifikovaná absorpce chlorofylu v indexu odrazivosti (*Modified Chlorophyll Absorption in Reflectance Index*)

MHSI Medicínské hyperspektrální snímání (*Medical Hyperspectral Imaging*)

-
- MLR** Vícenásobná lineární regrese (*Multiple Linear Regression*)
- MWIR** Středovlnné infračervené pásmo (*Medium-Wave Infrared Region*)
- NASA** Národní úřad pro letectví a vesmír (*National Aeronautics and Space Administration*)
- PCA** Analýza hlavních komponent (*Principal Component Analysis*)
- PLSR** *Partial Least Square Regression*
- PRI** Index fotochemické odrazivosti (*Photochemical Reflectance Index*)
- QIM** Metoda indexu kvality (*Quality Index Method*)
- ROI** Oblast zájmu (*Range Of Interest*)
- SAM** *Spectral Angle Mapper*
- SID** *Spectral Information Divergence*
- SIDSAM** *Spectral Information Divergence - Spectral Angle Mapper*
- SMD** Součástky určené pro povrchovou montáž (*Surface Mount Device*)
- SPOT** *Satellite pour l'Observation de la Terre*
- SVD** Singulární rozklad (*Singular Value Decomposition*)
- SVM** Metoda podpůrných vektorů (*Support Vector Machines*)
- SWIR** Viditelném blízké infračervené pásmo (*Short-Wave Infrared Region*)
- UV** Ultrafialové (*Ultraviolet*)
- VIF** Variabilní interferenční filtry (*Variable Interference Filters*)
- VNIR** Viditelné blízké infračervené pásmo (*Visible Near-Infrared Region*)
- WHC** Kapacita zadržování vody (*Water Holding Capacity*)

Seznam obrázků

1.1	Elektromagnetická vlna [3]	5
1.2	Elektromagnetické spektrum [4]	6
2.1	Průchod světla, stavba oka a umístění žluté skvrny [6]	8
2.2	Akomodace oka [6]	8
2.3	Zobrazovací soustava oka [2]	9
2.4	Zapojení fotoreceptorů a neuronů [6]	10
2.5	Sagitální řez bulbus oculi [9]	11
3.1	Spektrální odrazivost závisující na osvětlení vzorku	13
3.2	Hyperspektrální kostka [13]	14
3.3	Porovnání metod hyperspektrálního snímání [12]	17
3.4	SVM lineární prostory	19
4.1	Princip satelitního snímání	21
4.2	Mapa různých typů vegetace - satelitní snímek [24]	22
4.3	Hemoglobinové saturační mapy sítnice [30]	25
4.4	Distribuční mapy (spodní) a RGB snímky (horní) mletého masa [35] .	26
4.5	Distribuční mapy filetů ryb pro určení čerstvosti pomocí QIM [37] . .	28
5.1	Hyperspektrální soustava v laboratoři katedry radioelektroniky	32
5.2	Osvětlení stolu hyperspektrální kamery	34
5.3	Skenování vzorku a následné zpracování [11]	36
5.4	Falešný RGB snímek vzorků mletého masa z měření č.1	37
5.5	Falešný RGB snímek vzorků mletého masa z měření č.2	37
5.6	Reflektance vzorků mletého masa z měření č.1	37
5.7	Reflektance vzorků mletého masa z měření č.2	37
5.8	Měření č. 1: porovnání spektrálních metrik	38
5.9	Měření č. 2: porovnání spektrálních metrik	39
5.10	Rozdělení masa ve vzorku	41
5.11	Sedmikráska a reflektance jejích částí	42
5.12	Okvětní lístky tulipánů a jejich analýza pomocí SAM	42
5.13	Květy sakury a použití spektrální metriky SIDSAM	43
5.14	List pekingského zelí při oddělení natě a zelené části a reflektance . .	43
5.15	Salátová okurka a rozpoznání částí se slupkou a bez a jejich reflektance	44
5.16	Citrusy a rozpoznání dužiny od slupky a jejich reflektance	44
5.17	Pistácie a oddělení ořechu od skořápky a jejich reflektance	44

Seznam tabulek

4.1	Zajímavé vlnové délky	27
5.1	Parametry hyperspektrální kamery Specim PFD4K-65-V10E	33
5.2	Parametry Specim LabScanner 40 x 20	35
5.3	Měření č. 1	38
5.4	Měření č. 2	39
5.5	Kuřecí mleté maso	40
5.6	Hovězí mleté maso	40
5.7	Vepřové mleté maso	40

Úvod

Tato práce pojednává o hyperspektrálním snímání jako zobrazovací technologii a jeho aktuálním využití v oblasti biologie. První část práce je teoretická a uvádí souvislosti spojené s hyperspektrálním snímáním. Ve druhé části se věnuje praktické části, kde se nasnímaná data pomocí hyperspektrální kamery vyhodnocují.

Hyperspektrální snímání má za úkol zachytit data do 3D prostorové kostky, kde x a y jsou prostorové souřadnice a spektrální informace je λ . Principem je kombinace 2D zobrazování a spektroskopie. Oproti multispektrálnímu snímání, které předcházelo hyperspektrálnímu, zabírá hyperspektrální více úzkých spektrálních pásem.

Principem hyperspektrálního snímání je měření odrazivosti snímaných objektů. Každý objekt, někdy i různé části jednoho objektu odrážejí elektromagnetické záření jinak, a to umožňuje pomocí hyperspektrálního snímání je rozlišit.

Využití této technologie má velkou budoucnost. Jedním z prvních využití byl dálkový průzkum Země. Dodnes se hyperspektrální snímání k tomuto účelu používá a data jsou volně dostupná. V současnosti se hyperspektrální snímání používá ve velmi mnoha odvětvích, v průmyslu, v zemědělství, v medicíně a dalších. V biologických aplikacích ho můžeme nalézt například v kontrole potravin, chemické analýze potravin či farmaceutik, průzkumu zemědělské půdy a dalších.

Cílem této bakalářské práce bylo vytvořit přehled využití hyperspektrálního snímání biologických vzorků a poté pomocí hyperspektrální kamery vytvořit biologický datový set. Zároveň bylo cílem analyzovat nasnímaná hyperspektrální data pomocí algoritmů, což bylo realizováno programem HyperCalib v MATLAB a programem perClass Mira.

Kapitola 1

Parametry světla

V této kapitole budou stručně popsány parametry světla a základní zákonitosti z optiky. Podstatou světla a zkoumáním světelných jevů se zabývá optika.

Optika se dělí na tři typy podle různých přístupů výkladu světelných jevů a různých zákonů: paprsková, vlnová a kvantová optika. Paprsková optika, neboli geometrická optika úplně zanedbává vlnovou povahu světelného záření a zabývá se pouze tím, že světlo je paprsek. Základním kamenem je princip nezávislosti chodu světelných paprsků na přímočarém šíření světla. Základními zákony jsou zákon odrazu a zákon lomu. Vlnová optika se naopak nezabývá paprsky, ale vlnami. Zde se musí brát v potaz vlnová povaha světla. Zabývá se interferencí, ohybem a polarizací světla. Kvantová optika zkoumá děje, kdy se světlo šíří po tzv. kvantech. To znamená, že se světlo šíří jako proud částic, neboli fotonů a nešíří se spojitě jako u předchozích případů. Foton je kvantum elektromagnetického spektra a má povahu částice i vlny. Tento jev se nazývá vlnově-korpuskulární dualismus. Foton jako elementární částice má klidovou hmotnost a pohybuje se rychlostí světla c . [1]

1.1 Šíření světla

Světlo je část elektromagnetického záření, přesněji je to viditelná část elektromagnetického spektra. Můžeme ho charakterizovat pomocí několika hledisek jako například polarizace, koherence a další. Pro světelný paprsek platí také několik zákonů jako zákon odrazu, lomu či průchodu prostředím.

Vlastnosti prostředí, kterým světelný paprsek projde ho ovlivní. Mohou nastat různé případy interakce s prostředím. Jedním případem je absorpce světla, při které dojde k částečnému pohlcení světla určitých vlnových délek například pomocí barevných filtrů. Při disperzi neboli rozptylu světla se nepravidelně mění směr šíření světla například u matného prostředí. Posledním případem je, že světlo přes prostředí vůbec neprojde, ale odrazí se. Lom světla a odraz se řídí stejnými zákony, kde paprsek dopadne na rozhraní dvou prostředí s odlišnými vlastnostmi a světlo se na něm částečně odrazí a částečně se láme do druhého prostředí.

Existují tři typy optických prostředí. Prvním je průhledné optické prostředí, ve kterém nedojde k rozptylu světla. Prostředí, ve kterém dojde k částečné absorpci světla a zároveň k částečnému rozptylu, se nazývá průsvitné optické prostředí. Posledním optickým prostředím je neprůhledné optické prostředí, kde se světlo silně pohlcuje nebo se na rozhraní s daným prostředím jen odrazí. Dále můžeme optická prostředí dělit na opticky anizotropní nebo izotropní. V anizotropním prostředí závisí rychlost světla na směru, kterým se šíří. Naopak v izotropní látce je rychlost světla ve všech směrech stejná. [2]

1.2 Elektromagnetické záření

Jedním ze způsobu přenosu energie je elektromagnetické záření. Elektromagnetické záření se skládá ze dvou složek. Jednou složkou je elektrická složka, kterou charakterizuje vektor intenzity elektrického pole \vec{E} . Druhá složka je magnetická a ta je charakterizována vektorem magnetické indukce \vec{B} . Tyto dva vektory jsou na sebe kolmé (neboli ortogonální) a oba jsou zároveň kolmé na směr šíření elektromagnetické vlny (Obrázek: 1.1). Do elektromagnetických vln se řadí například rádiové vlny, viditelné světlo nebo gamma paprsky. Elektromagnetické vlny a vlastnosti elektromagnetického pole jsou popsány Maxwellovými rovnicemi, které jsou v diferenciálním tvaru. Ty vyjadřují čtyři fyzikální zákony: zobecněný Ampérův zákon celkového proudu

$$\nabla \times \vec{H} = \vec{j} + \frac{\partial \vec{D}}{\partial t}, \quad (1.1)$$

Faradayův zákon elektromagnetické indukce

$$\nabla \times \vec{E} = -\frac{\partial \vec{B}}{\partial t}, \quad (1.2)$$

Gaussův zákon

$$\nabla \cdot \vec{D} = \rho, \quad (1.3)$$

kde ρ značí hustotu a zákon o neexistenci magnetických nábojů

$$\nabla \cdot \vec{B} = 0. \quad (1.4)$$

Důležité je, že pro předchozí odvození Maxwellových rovnic, můžeme zavést materiálový vztah pro elektrickou indukci \vec{B}

$$\vec{B} = \mu \vec{H}, \quad (1.5)$$

kde μ značí permeabilitu. Poté materiálový vztah pro magnetickou indukci \vec{D}

$$\vec{D} = \epsilon \vec{E}, \quad (1.6)$$

kde ϵ značí permitivitu. Dále budeme uvažovat Ohmův zákon v diferenciálním tvaru

$$\vec{j} = \gamma \vec{E}, \quad (1.7)$$


kde γ je měrná vodivost. Permeabilita, permitivita a měrná vodivost budou považovány za konstanty.

Pro nevodivé prostředí je hustota volných nosičů náboje nulová, tedy $\rho = 0$. Upravíme tedy předešlé Maxwellovy rovnice a z toho nám vzniknou vlnové rovnice pro intenzitu elektrického pole \vec{E}

$$\Delta^2 \vec{E} = \frac{1}{c^2} \frac{\partial^2 \vec{E}}{\partial t^2} \quad (1.8)$$

a pro vektor magnetické indukce \vec{B}

$$\Delta^2 \vec{B} = \frac{1}{c^2} \frac{\partial^2 \vec{B}}{\partial t^2}. \quad (1.9)$$



Obrázek 1.1: Elektromagnetická vlna [3]

Rychlost šíření příčné vlny ve vakuu je $c = 299\,792\,458 \text{ m s}^{-1}$, což je zhruba zaokrouhleno na $3 \cdot 10^8 \text{ m s}^{-1}$. Pro výpočet rychlosti vlnění v obecném prostředí použijeme vzorec

$$c = \frac{1}{\sqrt{\epsilon_0 \mu_0}}, \quad (1.10)$$

kde ϵ_0 značí permitivitu vakua ($\epsilon_0 = 8,85 \cdot 10^{12} \text{ F m}^{-1}$) a μ_0 permeabilitu vakua ($\mu_0 = 4\pi \cdot 10^{-7} \text{ H m}^{-1}$). [4]

1.3 Elektromagnetické spektrum

Elektromagnetické záření se dělí dle různých vlnových délek respektive frekvencí do různých částí elektromagnetického spektra, které se také někdy nazývá Maxwellova duha (Obrázek: 1.2). Přechody mezi jednotlivými typy záření jsou postupné a často se překrývají. Spektrum jsme schopni rozdělit do následujících několika kategorií:


- rádiové vlny
- mikrovlny
- IR (infračervené záření)
- viditelná část

- UV (ultrafialové záření)
- rentgenové záření
- gamma záření

Pro hyperspektrální snímání jsou nejdůležitější především dvě části elektromagnetického spektra. Využívá se viditelné světlo a pak také z části IR oblast.

Viditelné světlo je světlo, které je schopno rozeznat lidské oko. V celém elektromagnetickém spektru tvoří velmi úzkou oblast. Do této kategorie patří světlo o vlnových délkách 380 – 760 nm. Lidské oko je schopno rozeznat ve viditelném světle různé barvy a je citlivé na vlnové délky zhruba 430 – 690 nm. Oko však může detekovat elektromagnetické vlny i za těmito limity, pokud jsou dostatečně intenzivní. [1, 4]

Infračervené záření je ve vlnových délkách 760 nm – 1 mm. Během pohlcování tohoto záření probíhá tepelná výměna a díky tomu se pozorované těleso zahřívá. Tento jev můžeme pozorovat pomocí infrakamery, která nám toto zahřívání ukáže. Infračervené záření využíváme v elektronice například v dálkovém ovladači, kdy ovladač obsahuje generátor impulzů, které jsou vyzařovány do prostoru pomocí polovodičové diody. Dále se infračervené záření využívá v komunikacích, kde je rozděleno do šesti kategorií. Dalším důležitým využitím je spektroskopie, která je rozepsaná v dalších kapitolách. [1]



Obrázek 1.2: Elektromagnetické spektrum [4]

Na zemský povrch jsou ovšem propouštěny pouze některé části tohoto spektra a to jsou rádiové vlny a viditelné světlo. V menší míře je atmosférou ještě propouštěno infračervené záření. Mezery v atmosféře propouštějící záření se nazývají jako tzv. spektrální okna. [4]

Kapitola 2

Lidský zrakový systém

Člověk je schopen díky svému zraku vidět a rozeznat různé barvy viditelného světla. Každá barva má svou vlnovou délku, kterou rozeznáme. Zrakový systém člověka HVS (Human Vision System) je složen z několika částí. Viditelné světlo projde lidským okem, kde se přemění na vzruchy. Ty dále putují skrze zrakový nervy do mozku, který je následně vyhodnotí. [5]

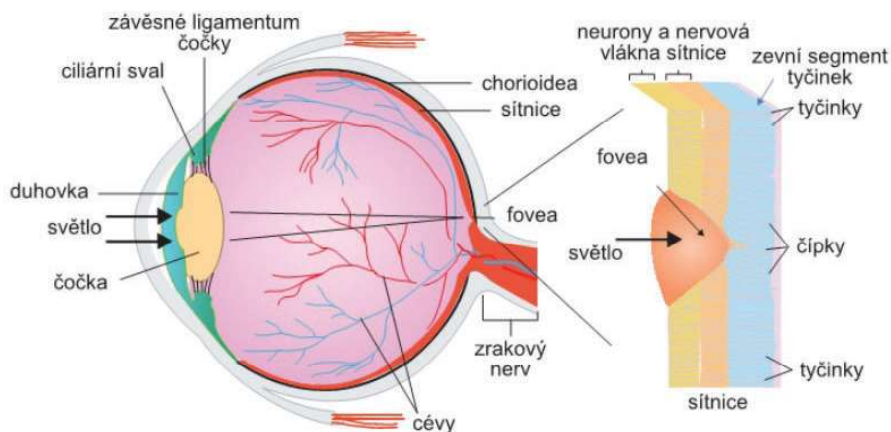
Hyperspektrální kamera je schopna zaznamenat kromě viditelného světla i část infračerveného spektra díky čipu, který je na něj citlivý. Na rozdíl od toho je lidské oko zaznamená pouze viditelnou část světla. To je možné díky dvěma typům světločivných buněk. Monochromatické vidění rozlišují buňky zvané tyčinky a RGB barvy rozlišují buňky zvané čípky. Oko narozdíl od hyperspektrální kamery nevidí v tolika kanálech. Má jen tři kanály (R, G, B), zatímco hyperspektrální kamera jich má stovky.

V této kapitole je více rozepsán lidský zrak a orgány, které jsou pro něj důležité.

2.1 Optická soustava

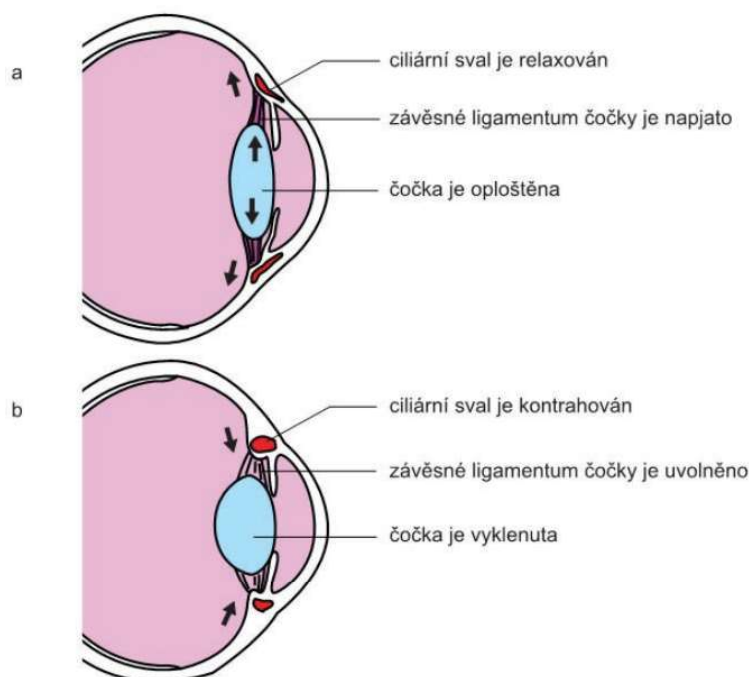
Lidské oko je optická soustava, která přemění viditelné světlo (440 – 760 nm) na vzruch. Oko je přizpůsobeno tak, aby propustilo co nejvíce dopadajícího světla. Z tohoto důvodu je většina částí průhledných, aby světlo nebylo nikde znehodnoceno. Jednotlivá průhledná prostředí mají různé indexy lomu (čočka - 1,406, sklivec - 1,336). [1]

Světlo dopadne na rohovku a čočku, které jej lámou a umožňují dopad paprsků na sítnici. Zde se nachází výše zmíněné světločivné buňky. Na rohovce dojde k největší změně chodu paprsků a to rozhodne o optické mohutnosti oka. Paprsek světla projde na zadní stěnu oka, kde se nachází sítnice a fotoreceptory, které paprsek vyhodnotí (Obrázek: 2.1).




Obrázek 2.1: Průchod světla, stavba oka a umístění žluté skvrny [6]

Oko pomocí čočky vytvoří obraz předmětů (Obrázek: 2.3), jenž nalezneme v různých vzdálenostech. Obraz je zmenšený, převrácený a skutečný. Důležitá pro ostrý obraz je akomodace oka, která je způsobena změnou zakřivení kruhového svalu oční čočky. Vzdálenost středu oční čočky od sítnice odpovídá její ohniskové vzdálenosti, jejíž hodnota je přibližně 1,6 cm. Rozsah vzdáleností, které může lidské oko akomodovat (Obrázek: 2.2), je dán dvěma body na optické ose oka. Jedná se o blízký bod a daleký bod. Blízký bod je nejbližší bod, který je oko schopno zobrazit ostře a uplatní se u něj maximální akomodace. Vzdálenost blízkého bodu je stanovena dohodou a nazývá se konvenční zraková vzdálenost d ($d = 25 \text{ cm}$). Nejevzdálenější bod na optické ose je bod daleký, kdy je sledovaný objekt okem vidět ostře bez akomodace. Daleký bod leží u zdravého jedince v nekonečnu. [1, 2]



Obrázek 2.2: Akomodace oka [6] - a) při pohledu do dálky, b) při pohledu do blízka



Obrázek 2.3: Zobrazovací soustava oka [2]

2.2 Lidské oko

Optická soustava je světlolomný systém oka usměrňující optické paprsky na světločivné buňky.

2.2.1 Světlolomný systém

Paprsky prochází skrze jednotlivé části oční koule (*bulbus oculi*), jejíž tvar je podobný kouli (Obrázek: 2.5). Z anatomického hlediska se oční koule dělí na tři vrstvy: vnější vazivovou (*tunica fibrosa bulbi*), střední cévnatou (*tunica vasculosa bulbi*) a vnitřní nervovou vrstvu (*tunica interna bulbi*). Dále oční koule obsahuje čočku (*lens*), sklivce (*corpus vitreum*) a oční komory (*camerae bulbi*).


Vnější vrstva oční koule je tvořena přední a zadní částí. Přední část je více zakřivená a je tvořena průhlednou rohovkou (*cornea*). Je bezbarvá, bezcévná a zcela průhledná pro lepší průchod paprsku. Zadní část je méně zakřivená a je tvořena bílou bělímou (*sclera*). Ta tvoří většinu povrchu oční koule. Z venku není bělima skoro vidět, jelikož je uložena v očníci.

Vrstva střední je tvořena cévnatkou (*choroidea*), řasnatým tělískem (*corpus ciliare*), duhovkou (*iris*) a zornicí (*pupilla*). Cévnatka je největší část střední vrstvy. Její funkcí je výživa oka cévami, které se v ní nacházejí. Na cévnatku navazuje řasnaté tělísko, na kterém je pomocí závěsného aparátu zavěšena čočka. Cévnatka napíná řasnaté tělísko, aby oko bylo schopno udržet zaostřený obraz na dálku. Pohyby řasnatého tělíska poté mění akomodaci čočky. Stahem řasnatého tělíska dochází k uvolnění závěsného aparátu, čočka se tím vyklenuje a získává konvexnější tvar. Tímto se zvyšuje optická mohutnost čočky, dochází k větší lomivosti paprsků. V důsledku dojde k akomodaci čočky a zaostření na blízko. Uprostřed duhovky se nachází zornice, skrze kterou prochází paprsek do sklivce. Duhovka funguje jako clona u fotografického objektivu, protože rozevívá a zužuje zornici. [7]

2.2.2 Světločivný systém

Do vnitřní vrstvy oka se řadí sítnice (*retina*) se dvěma speciálními oblastmi. První oblastí je slepá skvrna, kde nejsou žádné světločivné buňky a je to místo výstupu optického nervu. Druhou oblastí je žlutá skvrna, která je naopak místem s největším výskytem světločivných buněk a je zde místo nejostřejšího vidění. Ve žluté skvrně se nachází světločivné buňky čípky (Obrázek: 2.4). Ty jsou citlivé na světlo různé barvy, tedy i různé vlnové délky. Čípky zajišťují fotopické (denní) vidění. Druhý typ světločivných buněk jsou tyčinky vnímající světlo a tmu. Jsou více citlivé na nižší intenzitu světla a nezachycují barvy jako čípky. Zajišťují tzv. skotopické (noční) vidění.

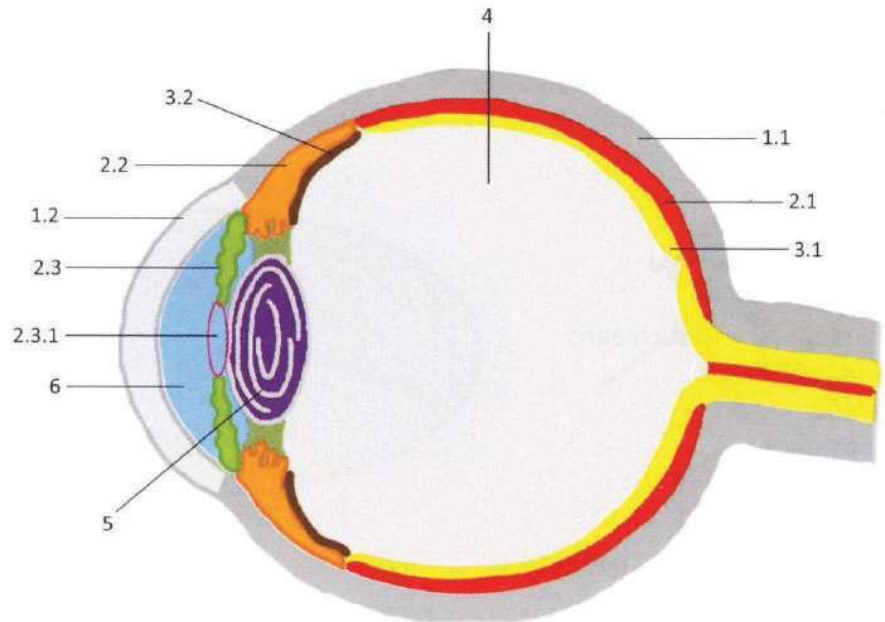
Paprsek se zachytí na světločivném pigmentu rhodopsinu (u tyčinek) a iodopsinu (u čípků), který po dopadu paprsků složitou kaskádou aktivuje bipolární neuron. Ten dále aktivuje gangliovou buňku, jejímž pokračováním je optický nerv. [8]



Obrázek 2.4: Zapojení fotoreceptorů a neuronů [6] - porovnání periferie sítnice a oblasti žluté skvrny

2.2.3 Vnitřek bulbus oculi

Důležitou částí oka pro optickou soustavu je čočka (*lens*). Její optická mohutnost je zhruba 10 – 17 dioptrií. Změna vyklenutí a tím i změna mohutnosti jsou základními funkcemi čočky. Většina vnitřku bulbus oculi je vyplněna sklivcem (*corpus vitreum*), což je průhledná, dokonale čirá a světlolomná vodnatá hmota. Součástí bulbus oculi jsou i dvě komory (*camerae bulbi*) - přední a zadní. Obě jsou vyplněny komorovým mokem. [7, 8]



Obrázek 2.5: Sagitální řez bulbus oculi [9]: 1 - vnější vazivová vrstva, 1.1 - bělma, 1.2 - rohovka, 2 - střední cévnatá vrstva, 2.1 - cévnatka, 2.2 - řasnaté tělísko, 2.3 - duhovka, 2.3.1 - zornice, 3 - vnitřní nervová vrstva, 3.1 a 3.2 - sítnice, 4 - sklivec, 5 - čočka, 6 - oční komory

2.2.4 Přidatné orgány

K těmto orgánům se řadí okohybné svaly (*musculi bulbi oculi*), fascie a vazivový aparát (*fascie orbitales*), víčka (*palpebrae*), spojivka (*tunica conjunctiva*) a slzný aparát (*apparatus lacrimalis*). Okohybných svalů je šest, čtyři jsou přímé a dva jsou šikmé. Slouží k otáčení oka. Víčka oko chrání stejně jako slzný aparát. [7, 8]

Kapitola 3

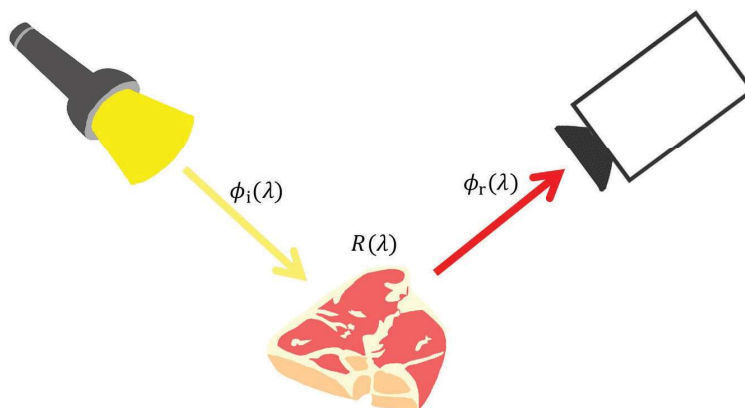
Hyperspektrální snímání

Jedním z nejdůležitějších základních principů fungování hyperspektrální snímání je, že každý materiál odráží, rozptyluje, vyzařuje a absorbuje elektromagnetické záření na různých specifických vlnových délkách. Každý materiál má rozdílné vlnové délky kvůli fyzikální struktuře, ale i chemickému složení. Hyperspektrální snímání se používá především pro část elektromagnetického spektra (viz. 1.2) od zhruba 200 nm (UV) do 2500 nm (blízké IR). [10]

Tato kapitola se zabývá samotným hyperspektrálním snímáním, jeho principy a následnými algoritmy analýzy hyperspektrálních dat jako jsou spektrální metriky a různé algoritmy typu SVM (Support Vector Machines) a PCA (Principal Component Analysis).

Nejčastěji se používá v hyperspektrálním snímání reflektanční spektroskopie (Obrázek: 3.1). Reflektanční spektroskopie se zabývá množstvím odraženého světla, které je následně zachyceno hyperspektrální kamerou. Na vzorek dopadne světlo s definovanou spektrální charakteristikou zářivého toku $\Phi_i(\lambda)$. To se odrazí od vzorku s definovanou spektrální charakteristikou zářivého toku $\Phi_r(\lambda)$. Tento mechanismus znázorňuje vzorec reflektance neboli odrazivosti, kde λ značí vlnovou délku [11]

$$R(\lambda) = \frac{\Phi_r(\lambda)}{\Phi_i(\lambda)}. \quad (3.1)$$



Obrázek 3.1: Spektrální odrazivost závisící na osvětlení vzorku

Hyperspektrální snímání se dá rozdělit podle druhu snímaného spektra na několik oblastí podle délky vln infračerveného záření. Prvním je krátkovlnné infračervené pásmo (SWIR - short-wave infrared region) odpovídající $1 - 3 \mu m$. Další je středovlnné infračervené pásmo (MWIR - mid-wave infrared region) s velikostí $3 - 5 \mu m$. Posledním je dlouhovlnné infračervené pásmo (LWIR - long-wave infrared region), které odpovídá velikosti $8 - 14 \mu m$. Pro tuto práci jsou ovšem nejdůležitější aplikace ve viditelném blízkém infračerveném pásmu (VNIR - visible near-infrared region), které se pohybuje v oblasti $0.3 - 1 \mu m$. [11]

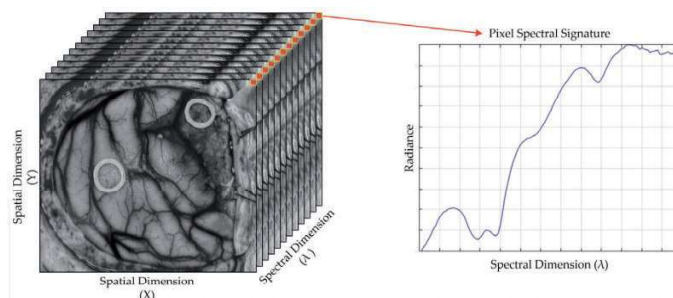
Hyperspektrální kamera zaznamená spektrum, které se skládá z desítek až stovek úzkých pásem vlnových délek o šířce jen několika nm. Multispektrální snímání je schopno zachytit nejčastěji méně než 10 pásem. Dále existuje ultraspektrální snímání zachycující až tisíce pásem.

Hyperspektrální snímání je v podstatě kombinací spektroskopie a zobrazovací techniky. Kamera je při hyperspektrálním zobrazování schopna nejen zaznamenat 2D obraz, neboli prostorovou informaci daného objektu jako je velikost, tvar nebo barva, ale také detailní spektrální informaci díky rozkladu světla disperzními prvky. Konečný hyperspektrální obraz je vytvořen z bloku 3D dat, který je složen ze dvou prostorových dimenzí a jedné spektrální dimenze. [10]

Výstupem hyperspektrálního snímání je tzv. datacube (Obrázek: 3.2), neboli hyperspektrální kostka. Ta se skládá z informace o prostoru (dimenze x a y) a z informace o spektru vzorku (λ), která se vyjádří na ose z . Získání datacube je možný nejčastěji pomocí čtyř následujících technik (Obrázek: 3.3):

- Whisk-broom
- Push-broom
- Staring
- Snapshot

Z hyperspektrální kostky jsme schopni extrahovat jednotlivá spektra. Můžeme z ní vytvořit i například spektrální mapy nebo můžeme pracovat stále s celou kostkou. [12]



Obrázek 3.2: Hyperspektrální kostka [13]: prostorové dimenze - osy x a y , spektrální informace - osa z

3.1 Metody snímání

Pro získání hyperspektrální kostky je nutné data nasnímat pomocí hyperspektrální kamery. Momentálně hyperspektrální kamery nejčastěji snímají pomocí jedné ze čtyř metod. Tyto metody jsou více níže rozebrány.

3.1.1 Whisk-broom

Whisk-broom, neboli point-scan je technika založená na snímání bod po bodu (rastrové snímání). Data se následně uloží do BIP kostky (Band-Interleaved-by-Pixel). Jedná se o klasickou spektrometrii, která je doplněna o optické prvky, která nám vyberou právě jeden bod snímané plochy. Nejčastěji se tato metoda používá ve fluorescenční mikroskopii nebo pro dálkové snímání Země. Prvně tato metoda byla použita družicí Earth Resources a také pro AVIRIS data¹. [12]

Snímanou plochu postupně skenujeme rotujícími zrcátky, které přeměrují odražené světlo do bodu, kde se nacházejí senzory. Během této metody se vzorek skenuje přes prostorové souřadnice x a y . Musíme tedy buď pohybovat vzorkem nebo kamerou. Nad každým bodem se světlo rozloží pomocí optického hranolu a pomocí toho získáme spektrální informaci. Tato spektrální informace se dále zachytí na lineární senzor s jedním řádkem. [14]

Nevýhodou této metody je její časová náročnost, jelikož se musíme pohybovat po obou osách x a y . Naopak výhodou je, že tento systém poskytuje velmi stabilní spektra s vysokým rozlišením. Další výhodou je, že má méně sensorových detektorů, které je třeba udržovat v kalibraci ve srovnání s jinými typy senzorů. Většina komerčních spektrálních konfokálních skenovacích přístrojů patří k tomuto druhu zobrazovacího režimu. [15]

3.1.2 Push-broom

Pomocí push-broom metody je skenován řádek po řádku (liniové snímání). Tato metoda je nejpoužívanější snímací metodou hyperspektrálního snímání. Byla například použita v některých družicových systémech pro pozorování Země z vesmíru, jako je systém SPOT² (franc. Satellite pour l'Observation de la Terre) nebo ALI (Advanced Land Imager), jehož provoz skončil roku 2017³. Data z metody push-broom se uloží do krychle BIL (Band-Interleaved-by-Line). [12]

Během snímání se rozdělí vzorek pomocí štěrbinu na jeden řádek. Následně díky disperznímu prvku rozložíme obraz na spektrum. Spektrum se bude nacházet na ose x a obrazovou informaci na ose y . I při této metodě musíme pohybovat buď vzorkem nebo kamerou. Zároveň je důležité tento pohyb synchronizovat s frekvencí snímání jednoho řádku, jinak by náš výsledek mohl být zkreslený. Abychom naskenovali vzorek, můžeme pohybovat vzorkem nebo kamerou, jak již bylo zmíněno, ale je také možnost umístit na kameru pohyblivou štěrbinu nebo rolovací závěrku. Tím se nám eliminuje neostře světlo. Zároveň tento přístup umožní větší propustnost světla.

¹<https://aviris.jpl.nasa.gov/>

²<https://earth.esa.int/eogateway/missions/spot>

³<https://www.usgs.gov/centers/eros/science/usgs-eros-archive-earth-observing-one-eo-1-ali>

Tento způsob je používán především v multispektrálních konfokálních mikroskopech.

Liniové snímání může oproti bodovému snímání získat více světla. Kamera může zůstat v určité oblasti delší dobu, což poskytne dlouhou expozici na maticovém detektoru a také relativně vysoké spektrální rozlišení. [14]

Výhodou je, že kamera s tímto typem snímání je malá a má velmi nízkou hmotnost. Nevýhodou je, že se musí použít dostatečně krátká doba expozice, aby se zabránilo riziku nekonzistencí na úrovni spektrálního pásma (saturace nebo podexpozice). [15]

3.1.3 Staring

Metoda staring nazývaná také plane scanning nebo pásmová sekvenční metoda zaznamenává prostorovou informaci a snímá spektrum postupně. V jednu chvíli pořídí celý černobílý snímek se souřadnicemi x a y se spektrem na jedné vlnové délce. Světlo se rozloží pomocí filtru. Data se uloží do pásmové sekvenční kostky BSQ (Band-Sequential).

Světlo projde skrze optickou část do filtru. Díky němu dopadne na senzor pouze jedna vlnová délka. To opakujeme buď pro různé vlnové délky nebo pro různé typy filtrů.

Tato metoda používá před maticovým detektorem filtry místo mřížky či hranolu pro rozdělení světelného paprsku. Filtry používané během této metody jsou například lineárně proměnné filtry LVF (Linear Variable Filters), variabilní interferenční filtry VIF (Variable Interference Filters) nebo filtry s pásmovou propustí.

Staring snímací metoda má oproti dvěma předešlým nižší spektrální rozlišení a také je její pořizovací cena mnohem větší. To jsou značné nevýhody této metody. Naopak výhodou je například krátký čas pořízení jednoho hyperspektrálního snímku. Dále nemusíme pohybovat ani kamerou ani vzorkem. Výhodou je i to, že si uživatel může vybrat různé vlnové délky a je schopen je během snímání měnit. [15, 12]

Díky popsaným výhodám, jako je krátká doba vytvoření datové kostky a možnost propojení s dalšími lékařskými přístroji, se tato metoda často využívá v medicíně. Další výhodou, kvůli které se v této oblasti používá, je, že mezi detektorem a vzorkem není potřebný skoro žádný prostorový pohyb. Příkladem využití v biomedicínských aplikacích je detekce orgánů, tkání a buněk in vivo nebo in vitro, při spojení s čočkou fotoaparátu, endoskopem nebo mikroskopem. [15]


3.1.4 Snapshot

Při metodě snapshot se zaznamená celý snímek najednou včetně prostorové i spektrální informace. Jedná se o nejnovější metodu ze všech popsaných v této práci. [12]

Díky zaznamenávání snímku najednou nemusíme vůbec měnit polohu kamery nebo snímaného vzorku nebo nemusíme měnit filtry. Toto je značná výhoda této

snímací metody. Oproti předchozím metodám má nižší spektrální i prostorové rozlišení a dále má omezenější počet spektrálních pásem. [16]

Díky časové nenáročnosti je tato metoda velmi vhodná pro časově citlivé experimenty jako je pozorování rychle difundujících molekul nebo stanovení časově rozlišených dynamických biologických procesů. Dále je také vhodná pro detekci map saturace kyslíkem v sítnici lidských očí při spojení s fundus kamerou. [15]



Obrázek 3.3: Porovnání metod hyperspektrálního snímání [12]: A - whisk-broom, B - push-broom, C - staring, D - snapshot

3.2 Analýza hyperspektrálních dat

Získaná hyperspektrální data v hyperspektrální kostce jsou následně analyzována pomocí algoritmu či spektrální metriky. Nejpoužívanější spektrální metriky jsou SID, SAM a SIDSAM. Další algoritmy používající se pro klasifikaci, regresi či segmentaci hyperspektrálních dat, jsou například SVM, PCA a další.

3.2.1 SID

Spektrální metrika SID (Spectral Information Divergence) vypočte spektrální podobnost založenou na rozdílnosti mezi pravděpodobnostními distribucemi testovaného spektra t a referenčního spektra r o délce C . Výpočet distribuční hodnoty referenčního spektra p_i (3.2) a testovaného spektra q_i (3.3) se dosadí do rovnice pro výpočet hodnoty SID (3.4). [17]

$$p_i = \frac{t_i}{\sum_{i=1}^C t_i} \quad (3.2)$$

$$q_i = \frac{r_i}{\sum_{i=1}^C r_i} \quad (3.3)$$

$$SID = \sum_{i=1}^C p_i \log \left(\frac{p_i}{q_i} \right) + \sum_{i=1}^C q_i \log \left(\frac{q_i}{p_i} \right) \quad (3.4)$$

3.2.2 SAM

SAM (Spectral Angle Mapper) je metrika, která rychle porovnává referenční spektra se spektry vzorků a srovnává jejich podobnosti. Předpokladem této metriky je, že data již byla zredukována na tzv. zdánlivou odrazivost s odstraněnými zkresleními. Algoritmus určuje spektrální podobnost mezi dvěma spektry pomocí výpočtu úhlu mezi zkoumanými spektry. Tato spektra považuje za vektory v prostoru s rozměrem, který se rovná počtu pásem. Výpočet algoritmu je arcus cosinus bodového součinu spekter. SAM určuje podobnost testovacího spektra t s referenčním spektrem r o délce C pomocí rovnice [18]

$$\alpha = \cos^{-1} \left(\frac{\sum_{i=1}^C t_i r_i}{\sqrt{\sum_{i=1}^C t_i^2} \sqrt{\sum_{i=1}^C r_i^2}} \right). \quad (3.5)$$

3.2.3 SIDSAM

Tato metrika měří také spektrální podobnosti. Je kombinací předchozích dvou zmíněných metrik SID (3.4) a SAM (3.5). V podstatě s jedná o hybrid těchto dvou metrik. Matematické vyjádření této metriky je [19]

$$SIDSAM = SID \times \tan(\alpha). \quad (3.6)$$


3.2.4 SVM

Metoda podpůrných vektorů SVM je algoritmus strojového učení používající se pro klasifikaci a regresi. Hledá optimální nadrovinu separující cvičná data. Separace dat může být lineární, ale i nelineární. Optimální nadrovina by měla být vzdálená od prvků jednotlivých tříd stejně. Cílem SVM je nalezení pouze jednoho lineárního oddělovače, který bude co nejširší a nebude se v něm vyskytovat žádný prvek. K popisu nadroviny slouží dva body, které jí jsou nejbližší a nazývají se podpůrné vektory. Těchto bodů je velmi málo. Data jsou pomocí SVM rozdělována do dvou různých tříd, to znamená, že metoda je binární. Jednou z důležitých vlastností SVM je schopnost z původně neseparovatelné úlohy udělat separovatelnou díky jádrové transformaci (kernel transformation). Jádrová transformace je funkce, která vezme nízkodimenzionální vstupní prostor a transformuje jej na prostor vyšší dimenze. SVM můžeme rozdělit do dvou typů pomocí zpracování dat na lineárně separovatelná data a lineárně neseparovatelná data (Obrázek: 3.4). [20]

Lineárně separovatelná data se řeší metodou nejmenších čtverců. Tato data mohou mít nekonečný počet řešení a právě proto SVM hledá největší vzdálenost mezi dvěma typy dat ve cvičné množině. Hledá se tedy maximální vzdálenost rozdělující body z cvičné množiny od klasifikátorů.

Neseparovatelná data jsou taková, která jsou si velmi podobná a více promíchaná v prostoru. Kdyby se použil algoritmus pro separovatelná data, došlo by k chybě. Výpočet těchto dat je velmi časově náročný, ale díky pokrokům a výzkumu se na ně nejvíce používají umělé neuronové sítě. [21]

Pro analýzu hyperspektrálních dat pomocí SVM je na vstupu hyperspektrální kostka (nebo více kostek), která se rozloží na jednotlivé pixely. Každý z těchto pixelů



Obrázek 3.4: SVM lineární prostory: A - separovatelná data, B - neseparovatelná data

reprezentuje bod v n -dimenzionálním prostoru, kde n je rovno počtu spektrálních kanálů. Pro trénovací část SVM jsou vybrány pixely náležící do specifických spektrálních skupin, nejjednodušeji do dvou.

3.2.5 PCA

PCA, neboli analýza hlavních komponent, je další z algoritmů používající se v následném zpracování a analýze hyperspektrálních dat. Nejvíce se používá ke snížení dimenze dat, aby byla co nejmenší ztráta informace. PCA našlo využití v rozpoznávání či kompresi dat. Převážně se použití najde k potlačení šumu nebo k redukci dimenze získaných dat. Druhý typ využití PCA je například rozpoznávání obličejů. Jednoduchou kompresí dat nalezneme u zpracování různých typů obrazu jako hyperspektrální či multispektrální. V kompresi PCA využívá vysoké korelace mezi jednotlivými spektrálními kanály a následně se převede obrázek.

Zjednodušený postup PCA je následující. Po získání dat se vytvoří kovarianční matice, která se rozloží pomocí singulárního rozkladu SVD (Singular Value Decomposition) na jednotlivé hodnoty. Z této matice se získají hlavní hodnoty, procentuální zastoupení původních proměnných hlavními komponentami a také se vytvoří diagonální matice latentních hodnot. Z diagonální matice se vypočte vlastní vektor a vlastní čísla kovarianční matice. [22]


Hyperspektrální data jsou pomocí PCA transformována a komprimována, aby bylo pak jejich použití snazší pro další analýzu.

Kapitola 4

Aplikace HSI

Použití HSI (hyperspektrálního snímání) se v poslední době velmi rozšiřuje. Můžeme ho nalézt nejen v průmyslu, ale i například v zemědělství nebo v medicíně. Jedním z prvních použití bylo zkoumání zemského povrchu z vesmíru. Obecně se HSI používá buď v průmyslových aplikacích a laboratořích nebo pro dálkový průzkum Země pomocí letadel nebo vesmírných satelitů, ve kterých jsou instalovány hyperspektrální kamery. Tato kapitola pojednává více o jednotlivých biologických využitích a algoritmech použitých ke zpracování a analýze biologických dat. Do biologických dat se řadí rostliny, maso či další potraviny jako ovoce, zelenina nebo ořechy. Do kategorie biologických dat se také řadí medicínská data nebo farmaceutika na biologické bázi.

Původně bylo HSI vyvinuto pro dálkový průzkum Země pomocí satelitu (Obrázek: 4.1). První systém vytvořený Alexanderem Goetzem a jeho kolegy z California Institute of Technology v 80. letech 20. století byl AIS (vzduchový zobrazovací spektrometr). Následně na to byl také tímto týmem roku 1987 vytvořen systém AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) zkoumající odražené sluneční spektrum v rozsahu vlnových délek 400 – 2500 nm. AVIRIS data jsou veřejně přístupná přes internet na stránkách NASA (viz. 3.1.1). Díky úspěchu tohoto systému došlo k velkému rozvoji HSI pro pozemní a vzdušné aplikace dálkového průzkumu. Dále to vedlo k aplikaci v dalších oblastech jako zemědělství, lékařství, potravinářství a dalších. [10, 23]

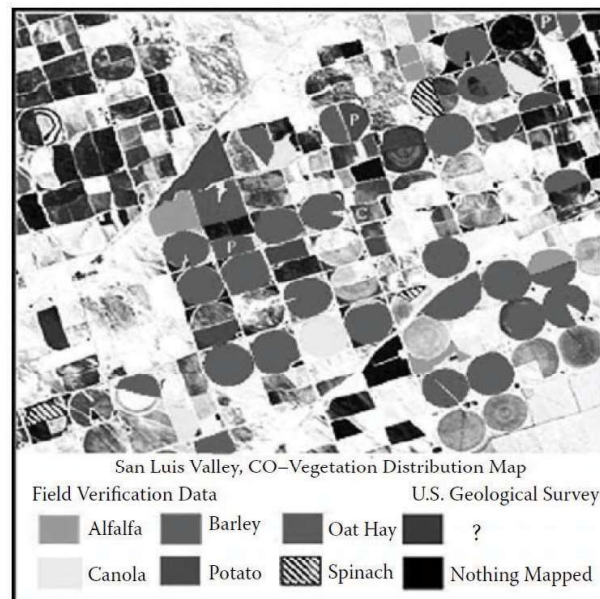


Obrázek 4.1: Princip satelitního snímání

4.1 Zemědělství

Do biologické oblasti patří zemědělství, kde se dá hyperspektrální snímání nalézt v různých odvětvích. Pomocí hyperspektrálního snímání se monitorují různé půdní podmínky a půdní živiny. Dále se sleduje kvalita a vlastnosti rostlin nebo kvalita vody.

Různé typy vegetace lze určit i díky spektrálnímu dálkovému průzkumu, protože například stresovaná vegetace a zdravá vegetace vypadají odlišně. Pomocí hyperspektrálního snímání lze rozlišit jednotlivé typy různých plodin [24] (Obrázek: 4.2). Farmáři si mohou objednat spektrální snímky svých polí, aby určili stav jejich půdy a všeho, co na ní roste. Spektrální snímky mohou například indikovat množství potřebné pro oplodnění na konkrétních místech, která jsou označena souřadnicemi GPS (Global Positioning System - globální polohový systém), Tyto informace mohou farmáři použít například k sázení hnojiva na základě informací obsažených ve spektrálních snímcích. Další průzkum byl pozorován u stromů, které trpěly stresem kvůli slanosti v půdě [25]. V USA na Floridě hledají nové hyperspektrální senzory rakovinu citrusů. [26]



Obrázek 4.2: Mapa různých typů vegetace - satelitní snímek [24]

Studie [27] z roku 1997 zkoumala pomocí vysokého spektrálního rozlišení detekci změn v různých parametrech růstu plodin jako LAI (LEAF Area Index – Index listové plochy), obsah chlorofylu nebo biomasu pomocí dálkového průzkumu. Zkoumaná oblast velikosti 10 x 2 km s různými podmínkami růstu pšenice spolu s holou půdou, která byla zasetá v polovině října a sklizena v polovině března, se nacházela ve státu Gujarat. Data byla snímána pomocí AIS (Airbone Imaging Spectrometer) ve výšce 3 km nad povrchem Země a GTR (Ground Truth Radiometer), který byl držen svisle přibližně 1,5 m nad polem, aby měřil odraženou záři. Pro měření byly vybrány vzorky deseti rostlin z každého pozemku. Ze studie vyplynulo, že pšenice má nízkou zářivost v červené oblasti a vyšší v oblasti infračervené oproti půdě.

Další způsob využití HSI je například popsáný ve studii [28]. Ta se zabývala detekcí obohacením živin a eutrofizací v mokřadech a dalších pobřežních oblastech. Výsledkem byl konzistentní pozitivní vztah mezi hladinami dusíku a reakcí rostlin v mokřadech Coyote Marsh v centrální Californii. Významná korelace s vodními živinami byla pozorována u dvou spektrálních indexů. Prvním byl index DCI (Derivative Chlorophyll Index), což je derivátový chlorofylový index. Dalším byl index fotochemické odrazivosti PRI (Photochemical Reflectance Index). Ukázalo se, že HSI by mohlo být velmi účinné pro detekci obohacení živinami a charakterizaci rostlin. Kromě výše zmíněných se ještě pomocí HSI dá sledovat MCARI (Modified Chlorophyll Absorption in Reflectance Index) index, který je schopen předpovídat LAI. [10]

4.2 Medicína

V posledních letech se začalo hyperspektrální snímání čím dál více využívat v medicíně. Používá se pro něj označení MHSI (Medical Hyperspectral Imaging). Hojné využití má v diagnostice a detekci onemocnění, ale i při operacích v kombinaci s dalšími metodami, jako magnetická rezonance nebo tomografie. Tato technologie našla využití v různých oblastech jako je digitální a počítačová patologie, detekce rakoviny, analýza rakovinných onemocnění in vivo a ex vivo, v laparoskopii nebo v kombinaci s konfokálním mikroskopem a dalších. HSI je také schopno diagnostikovat hemoragický šok, onemocnění periferních tepen, zubní kazy v raném stádiu, rychlou charakterizaci ledvinových kamenů, poruchy hrtanu a další. [13]

Výhodou použití hyperspektrálního snímání je jeho neinvazivita a nepotřeba označování biologických vzorků. V biologických tkáních jsme schopni měřit následující tři typy interakcí: refrakce, rozptyl a absorpce.

Kromě použití HSI v detekci či při operaci, nacházíme využití i ve snímání farmaceutik. Léky jsou zkoumány například kvůli časové degradaci jejich povrchu nebo jejich složení. Padělání léků je jedním z globálních problémů. I tento problém může být řešen pomocí HSI. Pro toto zkoumání byla použita NIR kamera s vlnovými délkami 900 – 1700 nm. Výsledná hyperspektrální data byla zkoumána pomocí PCA algoritmu. Došlo se k závěru, že v NIR části spektra lze některé falšované léky pomocí HSI rozpoznat a tudíž je zde velký potenciál do budoucna. [10]

4.2.1 Detekce

Pomocí HSI jsme schopni detekovat různé druhy nemocí jako rakovina, cukrovka, pozorování kůže či pozorování srdečních chorob. Momentálně se už některé aplikace MHSI těchto typů používají v klinických průzkumech.

Detekovat rakovinu pomocí HSI jsme schopni díky morfologickým a biochemickým změnám, které jsou spojené s lézemi. Ty mění rozptylové, absorpční a dokonce i fluorescenční vlastnosti. V téže oblasti bylo provedeno několik průzkumů, jak se rakovinné buňky chovají. V nových studiích se zkoumá použití HSI in vivo (v živém organismu) a v histologii, kde se ukazuje, že jak fluorescenční a reflektanční spektroskopie jsou schopny detekovat vzrůstající angiogenezi rakovinných buněk. Rakovina děložního čípku je jednou z nejvíce zastoupených rakovin na světě. Momentálně

se tento typ rakoviny vyšetřuje pomocí stíracího pap testu, který má ovšem zhruba 15%–40% falešně pozitivních výsledků. Další typ rakoviny zkoumaný pomocí HSI je rakovina kůže, přesněji melanomy a Kaposiho sarkom. V histologické studii Dickera a kol. [29], zkoumali rozdíly ve vzorcích benigních a maligních dermálních tkání, které byly obarveny hematoxylin-eosinovým barvivem. Spektrální rozdíly mezi těmito dvěma tkáněmi mohly být rozeznány pouze, pokud byla kontrolována doba obarvení vzorku a také jeho tloušťka. Dále se MHSI používá k diagnóze rakovinných buněk tlustého střeva, gastrointestinální soustavy, prsu, kůže, vaječníků a dalších. Algoritmy používané ke zpracování hyperspektrálních dat o rakovině jsou PCA a SVM. [13]


Další typ onemocnění, ve kterém se používá HSI jsou srdeční choroby. V současnosti se k diagnostice tohoto onemocnění používá angiografie, která zkoumá aterosklerózu, což je kornatění tepen v důsledku ukládání tukových látek v systému. HSI je velkým příslibem pro diagnostiku aterosklerózy tím, že sonduje velkou oblast zkoumané tkáně a poskytuje spektrální informace pro každý pixel v oblasti zájmu oproti klasické jednobodové spektroskopii. [13]

Pro pozorování oka a jeho částí se nejvíce v současnosti snažíme používat metody optického zobrazování, jelikož jsou neinvazivní oproti například biopsii. V oftalmologické diagnostice zkoumáme především změny retinální odrazivosti a absorpance světla, ke kterým dochází během rozvoje různých očních onemocnění. Spektrální informace získané z běžných digitálních snímků jsou velmi limitující, jelikož nám ukazují buď monochromatické nebo trichromatické světlo. Abychom tento problém vyřešili používáme s fundus kamerou i HSI, které vytvoří hyperspektrální krychli s informacemi z různých vlnových délek a shromáždí se tak tedy více spektrálních informací než s klasickým zobrazením sítnice. Také jsme schopni pomocí fundus kamery s HSI sledovat relativní prostorové změny v saturaci sítnice kyslíkem. Hemoglobinové spektrální signatury tuto saturaci zobrazí (Obrázek: 4.3). Tyto mapy vytvořil Johnson a kol. [30] pomocí snapshot HSI. Ukazují, jak kvalitativní, tak kvantitativní saturaci kyslíku v lidské sítnici. [31, 13]

Diabetes mellitus je jednou z nejrozšířenějších nemocí na Zemi. Často diabetici mají tzv. diabetickou nohu. To je nemoc, při které dochází k poškození tkáně. Následkem toho je ulcerace, gangrény nebo v nejhorším případě i amputace dolní končetiny, pokud se diabetická noha neléčí. Pomocí MHSI bylo u pacientů s diabetem zkoumána saturace hemoglobinu v tkáni. Bylo zjištěno, že u těchto pacientů je snížena saturace. Další studie prokázaly, že MHSI dokáže predikovat hojení diabetického vředu nebo dokonce posoudit riziko jeho rozvoje. [32, 13]

Velký potenciál MHSI se začíná objevovat v pozorování kůže. Především v jejích prostorových a časových změnách. Rané průzkumy byly prováděny na prasečí kůži vystavené šokem, který byl způsoben traumatem hrudníku a následným krvácením. Pozorovaly se změny úrovně okysličení kůže. Skvrnitý vzor saturace kyslíkem byl pozorován během hemoragického šoku nebo po resuscitaci. MHSI neinvazivně zobrazuje saturaci kyslíkem a je potenciálně užitečná při následné léčbě.

Kromě výše uvedených aplikací se můžeme s HSI v medicíně setkat v dalších diagnózách. HSI se může kombinovat s dalšími technikami jako je mikroskop či



Obrázek 4.3: Hemoglobinové saturační mapy sítnice [30]: A - zdravý muž (29 let), B - barevný obrázek nultého řádu, C - zdravý muž (58 let), D - barevný obrázek nultého řádu

makroskop, které slouží k histopatologickému vyšetření. Dále byl vyvinut snapshot HSI systém pro detekci celého spektra hemoglobinu s možností expozice jediného světla z fundus kamery. [13]

4.2.2 Operace

MHSI má potenciál rozšířit vidění chirurga na operačním sále na molekulární, buněčné či tkáňové úrovni. Velkou výhodou hyperspektrálního snímání je jeho schopnost rozlišit spektrální rozdíl normální a rakovinné tkáně téměř v reálném čase během výkonu. MHSI by mohlo monitorovat saturaci tkání kyslíkem během operace rychlostí zhruba tři snímky za sekundu a díky tomu by bylo schopno zachytit dynamické změny průtoku krve a neočekávané události během operace. Díky zobrazování v reálném čase je chirurg schopen stanovit či potvrdit diagnózu průběžně na operačním sále.

V chirurgii byla MHSI zkoumána v následujících operacích: mastektomie (operace karcinomu prsu), cholecystektomie (chirurgické odstranění žlučníku), nefrektomie (operace ledvin), břišní chirurgie a další. [13]

4.3 Potraviny


V této době potravinářský průmysl čelí několika výzvám jako uspokojení spotřebitele, ale i splnění potravinářských norem od kvality po bezpečnost. Většina analytických technik je kontaminující, časově náročná či nákladná. Kontrolu potravin provádějí lidé, kteří jsou sice vyškoleni, ale díky nim existuje riziko lidské chyby. Z tohoto důvodu se nyní snaží přejít co nejvíce k automatizaci kontrolních systémů založených na počítačovém vidění. Běžně se používají systémy pro detekci různých vnějších znaků, jako je velikost, barva, tvar nebo přítomnost různých defektů u různých typů potravin (maso, ryby, ovoce a další). Klasická spektrometrie oproti HSI

nesnímá prostorové informace, ale pouze spektrální a to nám umožní charakterizovat a vizualizovat spektrum jednotlivých pixelů. Pomocí HSI můžeme kvalifikovat fyzikální i chemické vlastnosti. [33]

4.3.1 Maso

Výzkumy v oblasti masa se zabývají především jeho kvalitou a pravostí. Několik novějších výzkumů se zabývalo HSI jako prekurzorem pro výběr vlnových délek pro následné použití na online multispektrálních přístrojích. Důvodem tohoto kroku je, že HSI systémy jsou v tuto chvíli velmi drahé a pro průmysl je snaha najít dostupnější a levnější možnosti.

Jedna ze studií, která bude v práci zmíněna se zabývá falšování mletého masa. Je to jeden z mezinárodních problémů. Díky různým spektrálním otiskům jednotlivých typů masa, můžeme pomocí hyperspektrálních kamer zjistit, zda se v mletém masu vyskytují nějaké příměsi. Snaha byla vybrat účinné vlnové délky pro masa typu hovězí, jehněčí, vepřové a kuřecí. Byl učiněn závěr, že pro vývoj multispektrálního systému bude nejlepší kombinace vlnových délek k určení stejného atributu v různých typech červeného masa. Toto ovšem není pro zpracovatele masa vhodné. V další studii [34] se pokusili navrhnout multispektrální systém v oblasti VNIR (400 – 1000 nm). Vybrali různé vlnové délky a navrhli systém, který v reálném čase vytvoří prognózu barevných pigmentů, obsah vlhkosti v masu a kapacitu zadržování vody. V jedné z prvních studií [35] zabývající se kontaminací jehněčího masa pomocí HSI byl použit rozsah 900 – 1700 nm elektromagnetického spektra. Na 200 vzorků následně aplikovali PCA a zjistili, že nejvíce je vidět falzifikace vepřovým masem. Dále z vybraných vlnových délek pomocí PLSR (Partial Least Square Regression) byly vybrány čtyři příznakové vlnové délky, ze kterých pak byl vyvinut MLR (Multiple Linear Regression) model. Pomocí tohoto modelu byly získány predikční mapy pro vizualizaci rozložení úrovně falzifikace ve vzorcích (Obrázek: 4.4). Kromě falšování jehněčího masa existují také studie na falzifikaci masa hovězího. Zkoumáno bylo falzifikování hovězího mletého masa masem kuřecím, vepřovým nebo koňským. Znovu zde bylo využito modelů PLSR a MLR.



Obrázek 4.4: Distribuční mapy (spodní) a RGB snímky (horní) mletého masa [35]

Pro kvalitu masa je důležitým faktorem jeho barva, jelikož spotřebitel maso hodnotí i po vizuální stránce. Ve stejné studii jako výše byl vyvinut online monitorovací systém pro barvu ($L^*a^*b^*$) se sadou vybraných vlnových délek v oblasti VNIR. L^* , a^* b^* je barevný prostor, kde a^* jsou zeleno-červené komponenty, b^* jsou modro-žluté barevné komponenty a L^* značí světelnost. L^* a^* b^* prostor je vyjádřen třemi číselnými hodnotami. Ve studii bylo vybráno šest vlnových délek, na základě kterých byl pomocí MLR stanoven kvantitativní lineární vztah mezi spektrálními daty a odpovídajícími barevnými parametry. Následující MLR kvantitativní funkce byly získány pro L^* , a^* a b^* , v daném pořadí. Tyto funkce lze použít k predikci parametrů barev v online systému. Nakonec byly generovány distribuční mapy předpokládaných barevných parametrů L^* , a^* a b^* aplikací odpovídající modelu MLR. Výsledky získané touto technikou lze použít pro automatizaci kontroly a třídění kvality na základě barevných hodnot červeného masa.

Kapacita zadržování vody WHC (Water Holding Capacity) je další z vlastností určující kvalitu masa. WHC je schopnost zadržovat vodu v mase po smrti, i když je na něj působen vnější tlak. Tento faktor je velmi ekonomicky důležitý, kvůli prodeji masa na váhu. Ve studii [36] zabývající se WHC byly vybrány dvě široce používané strategie výběru proměnných. Pomocí těchto strategií byly zvoleny různé vlnové délky, na něž byly vyvinuty modely PLSR a LS-SVM (Least-Square Support Vector Machines). LS-SVM mělo lepší výkon než PLSR. Na každý pixel byl tedy LS-SVM model aplikován pro získání predikčních map WHC.

Dalším faktorem zkoumaným pomocí HSI v masném průmyslu je vlhkost. Kontrola vlhkosti je důležitá pro proces konzervace, nakládání, uzení nebo sušení. Tento faktor také velmi ovlivňuje kvalitu a bezpečnost masa. Vlhkost velmi ovlivňuje mikrobiální růst důležitý pro trvanlivost masa. Momentálně se na kontrolu vlhkosti masa používají velké a drahé analytické systémy. Ve studii [34] navrhli multispektrální zobrazovací systém pro předpověď obsahu vlhkosti v reálném čase. Pomocí PLSR bylo vybráno deset charakteristických vlnových délek z celého spektrálního rozsahu 121 vlnových délek. Poté byl vyvinut MLR model, který předpověděl obsah vlhkosti na celém povrchu vzorku masa. Také byly vytvořeny distribuční mapy ukazující výhody použití HSI. Tyto mapy nelze získat klasickým zobrazováním nebo spektroskopii.

HSI v masném průmyslu má velkou budoucnost. Pomocí HSI je možné kontrolovat kvalitu, bezpečnost nebo detekovat falzifikáty v mase. Díky studiím, které byly provedeny už teď můžeme říci, jaké jsou vhodné vlnové délky pro zkoumání určitých typů mas (tabulka: 4.1). Technologie je zatím pro masný průmysl drahá, ale do budoucna pokud bude optimalizována a vyvinuta pro snímání v reálném čase, bude možná její potenciál využít. [33]

Typ masa	Vybrané vlnové délky
Hovězí	934, 1048, 1108, 1155, 1185, 1212, 1265, 1379
Vepřové	960, 1057, 1131, 1211, 1308, 1394
Jehnečí	927, 950, 1047, 1211, 1325, 1513, 1645


Tabulka 4.1: Zajímavé vlnové délky

4.3.2 Ryby

Díky nutričnímu složení ryb se s nimi můžeme setkat v mnoha typech dietních pokrmů. Jednou z nejdůležitějších složek ryb jsou omega-3 nenasycené mastné kyseliny. Lidský organismus postrádá enzymy pro tvorbu těchto kyselin a musí je brát z potravy. Tyto enzymy se právě ve velké míře vyskytují v rybách a dalších druzích potravin pocházejících z moře. Znovu se klade velký důraz na kvalitu ryb, jejich přepravu a uskladnění. Pro kvalitu, čerstvost, chemické složení a především kontrolu mikrobiálního stavu ryb se v několika posledních letech začalo používat HSI.

Konvenční zavedené metody a analytické techniky jsou obecně časově náročné a velmi drahé. Při těchto kontrolách je potřebný kvalifikovaný personál, což je v terénu velmi obtížné. HSI tedy kromě neinvazivity, časové nenáročnosti vykazuje další výhody šetrnost k životnímu prostředí.

Čerstvost ryb ovlivňuje jejich nutriční kvalitu, bezpečnost a požitelnost. Tento faktor může být ovlivněn jak chemickými, fyzikálními, tak biochemickými a mikrobiologickými procesy. Jedním z důležitých indexů čerstvosti je hodnota K. Ta se používá pro hodnocení chemického znehodnocení a degradaci nukleotidů. Optimální hodnota K se pohybuje okolo 20%. Její zvýšení indikuje bakteriální kažení a pokud hodnota K dosáhne 60%, je vzorek odmítnut. Další metodou pro popis čerstvosti ryb je metoda indexu kvality QIM (Quality Index Method). Tato metoda je jednou z nejzdravějších a nejpřímějších způsobů, ale je velmi časově náročná. Nedá se použít ve větším měřítku a je velmi subjektivní. Ve studii [37] byly použity HSI snímky vnějšího povrchu filetu tresky. Z těch byla změřena průměrná spektra oblastí, kde bylo nejvíce vidět různé působení času (Obrázek: 4.5). V této studii byl použit algoritmus částečné regrese pomocí nejmenších čtverců.



Obrázek 4.5: Distribuční mapy filetů ryb pro určení čerstvosti pomocí QIM [37]: (a) QIS = 2, (b) QIS = 4, (c) QIS = 7, (d) QIS = 9, (e) QIS = 11, (f) QIS = 15

Dalšími zkoumanými parametry je vlhkost nebo obsah soli. Sůl NaCl (*natium chlorid*, chlorid sodný) díky svým vlastnostem většinou prodlouží dobu trvanlivosti ryb. U filetů z lososa ji dokonce prodloužila zhruba na šest týdnů.

Kromě fyzikálních vlastností se mohou v rybách pomocí HSI zkoumat biologické parametry a dokonce i parazité. Příkladem zdraví škodlivých parazitů pro lidský organismus v rybách jsou háďátka. Detekce parazitů v rybách byla provedena v několika studiích se závěrem, že pomocí spekter lze odlišit parazity od rybího masa a dokonce i říci přesně, v jaké hloubce se parazité nacházejí. [33]

4.3.3 Ovoce a zelenina

HSI je pro ovoce a zeleninu používáno pro kontrolu kvality, bezpečnost potravin, ale i nedestruktivní analýzu vnitřku ovoce nebo zeleniny.

Kvalita ovoce je definována jako soubor znaků či vlastností určující, zda ovoce bude konzumovatelné či ne. Mezi tyto charakteristiky patří vzhled, textura a chuť. Momentálně je třídění ovoce automatické nebo ho třídí člověk. Při ručním třídění je riziko výskytu lidské chyby. Toto je důvodem hledání nových možností rychlé, přesné a zároveň neinvazivní analytické techniky, schopné hodnotit kvalitu a kontrolovat bezpečnost. Strojové vidění a NIR spektroskopie jsou dvě metody, které se již nyní široce používají v potravinářském průmyslu. Spektroskopie je používána pro zobrazení chemických složek, jako například nedestruktivně vyhodnotit obsah cukru. Algoritmy strojového učení řeší vnější charakteristiky ovoce a zeleniny. Mezi tyto algoritmy patří PCA, PLSR, SVM a další.

Z oblasti ovoce se pomocí HSI zkoumala jablka, citrusy, hrušky a broskve v odrazovém režimu v rozsahu VIS-NIR. Novější studie se více zabývají rozsahem NIR. Zkoumala se například moučnatost jablek, kdy korelace hyperspektrálního rozptylu byla predikována pomocí PLSR.

Ze zeleniny byly zkoumány různé typy jako sójové boby, salát, papriky, cibule, rajčata a další. U sójových bobů byla pomocí HSI detekováno poškození hmyzem, analýza barvy, pigmentu, sladkost a další. Ve studii [38] byla zkoumána detekce přítomnosti dutého srdce u brambor. Tato vnitřní porucha hlíz brambor byla zkoumána pomocí HSI v IR oblasti. Použili SVM algoritmus, který dosáhl přesnosti téměř 90% správné klasifikace. Dále byla zkoumána detekce škrobu v bramborách. Nejdříve byla původní spektra zpracována metodou PLSR a následně pomocí PCA. PCA vyšel jako nejlepší ze všech predikčních modelů. U rajčat bylo zkoumáno zrání, vnější poškození a poškození škůdci nebo barva. Defekty se zkoumaly i u okurek spolu s poraněním mrazem. Jednoduché algoritmy spektrálních pásem nebo PCA byly použity k rozlišení spekter oblastí zájmu ROI (Range Of Interest) dobrých a mrazem narušených slupek. PCA detekovalo s úspěšností přes 90%. Výsledkem bylo, že odrazivost pohmožděných okurek byla mnohem nižší než u normálních okurek. Pomocí algoritmu PCA bylo zkoumáno i vnitřní mechanické poškození v okurkách. Výsledkem bylo, že se přesnost detekce pomocí PCA během šesti dnů snížila o 20%. U hlávkového salátu se pomocí HSI predikoval obsah dusíku v listech ve spektru NIR a VIS. Dále se u hlávkového salátu a špenátu pomocí fluorescenční HSI detekovala fekální kontaminace. U špenátu se zkoumala kontaminace bakterií *Escherichia coli* a byla vyvinuta velmi rychlá metoda založená na HSI. Pro odstranění nadbytečných informací z hyperspektrálních dat byl použit algoritmus PCA. Pro papriky bylo provedeno srovnání mezi předzpracovanými spektry a PLSR analýzou spekter odrazivostí. Poslední zkoumanou zeleninou je cibule, u které se řešily vnitřní atri-

buty. Problémem u cibule je její nerovnoměrný tvar, což má za následek různý odraz v různých polohách na povrchu cibule. [33]

V jedné studii byla kontrolována kvalita cibulí pomocí laditelných filtrů z tekutých krystalů LCTF (Liquid Crystal Tunable Filters). Tato technologie ukázala, že LCTF ukáže oku neviditelné bakteriální nemoci a dokáže předpovědět vnitřní kvality cibule. [39]

Kapitola 5

Analýza nasnímaných dat

V laboratoři ČVUT katedry radioelektroniky se nachází hyperspektrální kamera Specim PFD4K-65-V10E, která bude v této kapitole popsána. Pomocí této kamery bylo nasnímano několik biologických vzorků, z nichž byl následně vytvořen datový set o 45 snímcích. Získaná hyperspektrální data byla následně vyhodnocena pomocí počítačových programů. Jeden hyperspektrální obrázek je velikostně moc velký, proto je celý datový set dostupný na katedře radioelektroniky fakulty elektrotechnické ČVUT.

5.1 Hyperspektrální soustava

Hyperspektrální setup (Obrázek: 5.1) v laboratoři katedry radioelektroniky byl vyroben firmou Specim a skládá se ze dvou částí. Hyperspektrální kamera typu PFD4K-65-V10E, která je nainstalovaná na laboratorní skener LabScanner 40 x 20. Kamera je připojena na stolní počítač, ve kterém jsou nainstalovány programy použité v této bakalářské práci pro naskenování biologických vzorků a následnou analýzu některých z nich. Jedná se o programy LUMO software od Specim¹, perClass Mira² a HyperCalib více popsány v [40] v MATLAB³.

5.1.1 Hyperspektrální kamera Specim PFD4K-65-V10E

Tato hyperspektrální kamera je založena na principu liniového skenování (viz. 3.1.2). Během nasnímání každého řádku dojde k rozložení každého pixelu na celý spektrální rozsah kamery. Výrobce uvádí, že kamera má rozsah 400 – 1000 nm vlnových délek, což spadá do oblasti VNIR (visible near-infrared) elektromagnetického spektra. Kamera má velmi vysokou rychlost odrazu, vysoké rozlišení a jsme schopni si vybrat druh vlnové délky. Výrobce uvádí, že díky konstrukci je tato kamera vhodná pro průmyslové využití jako například pro kontrolu kvality, průzkum jídla, rostlin a vegetace, online třídění a monitorování kvality, monitorování životního prostředí nebo k detekování padělků.

Kamera Specim PFD4K-65-V10E v laboratoři katedry radioelektroniky je typu CASED. Má prostorové rozlišení 1775, což je velmi vysoké rozlišení v porovnání s

¹<https://www.specim.fi/products/lumo-family/>

²<https://www.perclass.com/perclass-mira/product>

³<https://www.mathworks.com/products/matlab.html>



Obrázek 5.1: Hyperspektrální soustava v laboratoři katedry radioelektroniky

dalšími kamerami na trhu. Toto rozlišení je takto vysoké díky push-broom metodě snímání. Pro následný rozklad světla je nutné, aby tato kamera měla integrovanou štěrbinu a v případě použité kamery má štěrbinu šířku $30 \mu\text{m}$. Celkové rozměry kamery jsou $33 \times 8.5 \times 9 \text{ cm}$ a její váha činí $2,7 \text{ kg}$. Kamera má snímkovací frekvenci 100 snímků za sekundu a nasnímá celkem 768 spektrálních pásem. Další parametry jsou přehledně zapsány v Tabulce (5.1)⁴.

Kamera podporuje software LUMO, který byl vyroben firmou Specim. Firma Specim uvádí, že LUMO software je schopen nastavit různé parametry kamery, sbírat data a následně je ukládat na pevný disk počítače a vizualizovat obraz v reálném čase. Výsledné datové kostky jsou kompatibilní s ENVI, což umožňuje další zpracování několika softwarovými balíčky pro hyperspektrální zpracování dat.

Firma Specim vyrábí několik typů kamer. Kamera typu PFD4K-65-V10E je dodávána s jedním ze tří typů objektivů. Hyperspektrální kamera Specim PFD4K-65-V10E v laboratoři ČVUT má objektiv typu OLE 23, který má úhel záběru $34,3^\circ$. Clonové číslo používané kamerou je $F/2,4$.

Tělo kamery je ve výšce 28 cm nad pojízdným stolem Laboratorního skeneru Specim LabScanner 40×20 . Přesná vzdálenost pojízdného stolku od objektivu kamery je 24 cm .

⁴<https://www.specim.fi/products/pfd4k-65-v10e/>

Optické charakteristiky		Elektrické charakteristiky	
Spektrální rozsah	400 - 1000 nm	Detektor	CMOS
Spektrální rozlišení FWHM	3.0 nm	Prostorové pixely	1775
Spektrální vzorkování	0.78 - 6.27 nm/pixel	Spektrální pásma	768
Prostorové rozlišení	velikost bodu RMS < 9 μm	Velikost pixelů	8x8 μm
F/#	F/2.4	Kamerový výstup	digitální 12 bit
Šířka štěrby	30 μm	Rozhraní	Base CameraLink
Efektivní délka štěrby	14.2 mm	Ovládání kamery	CameraLink
Celková typická účinnost	> 50% - nezávislé na polarizaci	Snímkovací frekvence	až 100 fps
Rozptýlené světlo	< 0.5% (halogenová lampa, 590 nm LPF)	další funkce	Spektrální binning až x 8, více oblastí zájmu buď v prostorovém nebo spektrálním směru
Environmentální charakteristiky		Rozsah doby expozice	0.1 - 100 ms
Skladování	-20 - +50°C	Spotřeba energie	< 5W
Provoz	+5 - +40°C	Vstupní napětí	24 V
Mechanické charakteristiky			
Velikost		33 x 8.5 x 9 cm	
Váha		2.7 kg	
Tělo		eloxovaný hliník s otvory pro šrouby na montování	
Uchytení objektivu		standardní bajonet typu C	
Závěrka		ovládána přes USB	

Tabulka 5.1: Parametry hyperspektrální kamery Specim PFD4K-65-V10E

5.1.2 Laboratorní skener Specim LabScanner 40x20

Laboratorní skener má celkové rozměry 703 x 335 x 710 mm a váží 13 kg. Samotná posuvná plocha, neboli stůl má rozměry 400 x 200 mm. Maximální hmotnost vzorku může být až 5 kg. Rychlost posunu lze nastavit v rozmezí od 0,1 mm/s do 99 mm/s. Další parametry jsou v Tabulce (5.2)⁵.

Stůl je osvětlen několika zdroji (Obrázek: 5.2). Původně od výrobce byla na sestavě stolu namontována jedna halogenová lampa, která obsahuje tři halogenové zářiče Decostar 51 ALU 36deg GU5.3. Ta ovšem vrhala stín z jednoho směru na vzorek. Z toho důvodu byla naproti ní nainstalována další halogenová lampa, aby byl vzorek lépe osvětlen z obou stran. Tato halogenová lampa je stejného typu jako předchozí. Dalším problémem kamery byla neschopnost detekce modré a UV oblasti elektromagnetického spektra, proto byly před jednu halogenovou lampu namonto-

⁵<https://www.specim.fi/products/labscanner-40x20/>

vány čtyři modré LED (elektroluminiscenční diody) pásky o délce 12,5 cm a před druhou čtyři UV LED pásky se stejnou délkou.



Obrázek 5.2: Osvětlení stolu hyperspektrální kamery: A a D - halogenové lampy, B - UV LED pásky, C - modré LED pásky

Modré LED pásky IP50 LED mají LED čip 3528 SMD (součástky určené pro povrchovou montáž) a jejich příkon je 9,6W na 1 metr⁶. UV LED pásky mají LED čip 5050 SMD San'an a jejich relativní příkon je 14,4 W na metr⁷. Oba typy LED pásek mají úhel svitu 120°.

Další funkcí skeneru je možnost posuvu ve vertikálním směru. Kamera je momentálně nastavena na výšku 28 cm od posuvného stolu a během měření se její poloha nemění.

Sken je ovládán spektrální kamerou nebo samostatným kabelem vedoucím do počítače, kde je nainstalována softwarová sada LUMO skeneru Specim. Na sken je možno namontovat několik druhů kamer od dodavatele Specim. Některé typy však nelze napájet pomocí výstupního konektoru skeneru.

⁶<https://www.t-led.cz/p/led-pasek-vodeodolny-sq3-w600-7311>

⁷<https://www.t-led.cz/p/uv-led-pasek-144w-original-uv-cip-7803>

LabScanner 40x20	
Velikost (délka X šířka X výška)	703 x 335 x 710 mm
Nastavení výšky kamery	volitelné, 200 mm
Rozměry posuvného stolu	400 x 200 mm
Hmotnost	13 kg +/- 10%
Maximální hmotnost vzorku	5 kg
Skenovací rychlost	0,1 mm/s - 99 mm/s
Ovládací rozhraní	Prostřednictvím spektrální kamery nebo pomocí samostatného ovládacího kabelu (USB nebo RS232)
Osvětlení	DECOSTAR 51 ALU 20W 12V 36deg GU5.3 halogen
Vstupní napětí	nominální 100...240 VAC
Výstupní napětí	12V DC
Výstupní proud	26,7 A
Maximální spotřeba energie (včetně motoru skeneru, osvětlení, FX17)	Duální osvětlení: 170W

Tabulka 5.2: Parametry Specim LabScanner 40 x 20

5.2 Postup snímání a vyhodnocení

Před celým snímáním a zpracováním dat biologického vzorku (Obrázek: 5.3) je potřeba předzpracování dat. Nejdříve je nutné, aby byl minimalizován šum kamery a světelných efektů. To se nazývá radiometrická kalibrace, která probíhá ve dvou krocích, Nejdříve je pořízen snímek bílého referenčního spektra tzv. white frame. Kalibračním cílem je bílý obdélník položený na snímacím stole, který má odrazivost zhruba 99%. Poté, je udělán tmavý snímek, tzv. dark frame, který je pořízen se zavřenou záklopkou kamery. Při obou krocích je zachyceno několik snímků. Výsledný vzorec reflektance i s kalibracemi


$$R(x, y, \lambda) = \frac{I_m(x, y, \lambda) - I_{dark}(x, y, \lambda)}{I_{white}(x, y, \lambda) - I_{dark}(x, y, \lambda)}, \quad (5.1)$$

kde I_{white} značí white frame, I_{dark} dark frame a I_m je reflektance měřeného obrázku. Jak již bylo výše zmíněno x a y jsou prostorové souřadnice a λ je vlnová délka. [39]

Všechno nastavení hyperspektrální kamery Specim PFD4K-65-V10E a laboratorního skeneru bylo provedeno pomocí programu LUMO software od firmy Specim.

Po kalibraci byl dán biologický vzorek na pohyblivý stůl pod optiku kamery. Po vhodném nastavení rychlosti stolu se začal biologický vzorek liniově snímat (viz. 3.1.2). Následně byl digitálně vytvořen hyperspektrální obrázek. Tyto obrázky mají velkou velikost a jejich zpracování je výpočetně náročné.

Po vložení dat do programu HyperCalib byly vybrány jednotlivé ROI ze vzorků. Díky tomuto kroku bylo vytvořeno průměrné spektrum přes všechny vybrané pixely a tím se mi zmenšil šum naměřeného vzorku. Poté byl vytvořen graf reflektance pro jednotlivé vzorky. Pro provedení bylo nutno odlišit pozadí a vzorky daného obrázku.



Obrázek 5.3: Skenování vzorku a následné zpracování [11] - kamera s jednou halogenovou lampou

Byla vytvořena maska pro segmentaci, která se následně exportovala do MATLAB. Dalším krokem po segmentaci dat byla aplikována jedna ze spektrálních metrik SID, SAM nebo SIDSAM (viz. 3.2). Pro každou spektrální metriku se vybral threshold a byl proveden výpočet. Program vytvořil .mat soubor pro jednotlivé ROI, které byly v obrázku vybrány. Z těchto souborů se pak spektra porovnávala. Všechny tyto soubory jsou v příloze.

Při vložení dat do programu perClass Mira byla nejdříve vytvořena hyperspektrální kostka. Následně byly vytvořeny třídy, v nichž kromě oddělení pozadí od vzorků, bylo možno oddělit jednotlivé typy vzorků. Bylo pak vytvořeno průměrné spektrum. Program pracuje se standardními knihovnami pro hyperspektrální analýzu a využívá algoritmy jak graph cut segmentaci [41], matematické operace se spektry a jiné.

Pro zobrazení obrázků z datového setu v této práci budou použity tzv. „falešné RGB“ snímky. V těchto snímcích jsou zvoleny tři vlnové délky. Hyperspektrální obrázky nejsou použity kvůli jejich velikosti. Jeden z hyperspektrálních obrázků je v příloze spolu s dalšími obrázky, které reprezentují různé typy analýz a spektrálních charakteristik nasnímaných biologických vzorků.

5.3 Nasnímané vzorky


Jedním z cílů bakalářské práce bylo vytvoření databáze hyperspektrálních snímků různých biologických vzorků. V této databázi jsou vzorky různých typů mletého masa (kuřecí, hovězí, vepřové), zeleniny (paprika, list pekinského zelí, okurka salátová), rostlin (tulipán, sedmikráska) a ořechů (pistácie).

5.3.1 Mleté maso

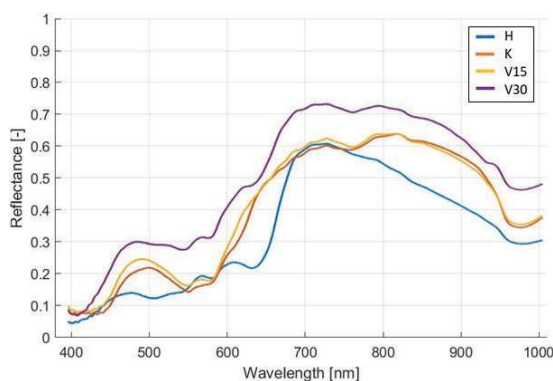
Jedním z typů nasnímaných dat bylo mleté maso. Byla provedena dvě měření. V prvním měření byly použity čtyři vzorky mletého masa (Obrázek: 5.4): hovězí, kuřecí a vepřové s 15% a 30% tuku. Druhé měření bylo také provedeno se čtyřmi vzorky (Obrázek: 5.5): hovězí, vepřové a kuřecí, přičemž jedno z nich bylo kupované a druhé namleté doma. Na všechny tyto vzorky byly pomocí programu HyperCalib aplikovány spektrální metriky (viz. 3.2). V tabulkách (5.3) a (5.4) jsou vidět rozdíly mezi jednotlivými spektry pomocí třech výše zmíněných metrik (viz. 3.2). Čím je číslo vyšší, tím jsou spektra od sebe více vzdálena a odlišnější. Dále byly vytvořeny grafy reflektance, kde každá křivka představuje jednu spektrální charakteristiku daného vzorku.



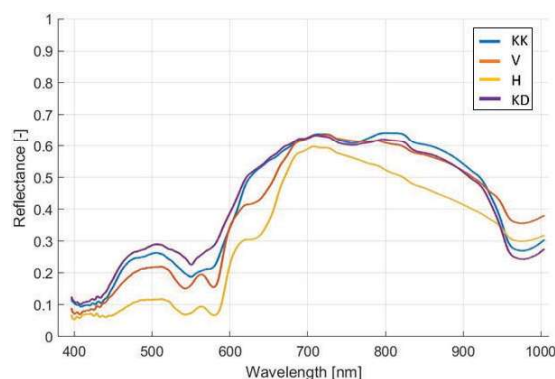
Obrázek 5.4: Falešný RGB snímek vzorků mletého masa z měření č.1: A - hovězí, B - kuřecí, C - vepřové 15% tuku, D - vepřové 30% tuku



Obrázek 5.5: Falešný RGB snímek vzorků mletého masa z měření č.2: A - kuřecí kupované, B - vepřové, C - hovězí, D - kuřecí domácí



Obrázek 5.6: Reflektance vzorků mletého masa z měření č.1: H - hovězí, K - kuřecí, V15 - vepřové 15% tuku, V30 - vepřové 30% tuku




Obrázek 5.7: Reflektance vzorků mletého masa z měření č.2: KK - kuřecí kupované, V - vepřové, H - hovězí, KD - kuřecí domácí

V měření č. 1 byly použity následující koupené vzorky mletého masa: hovězí mleté maso z Masozávodu Modletice, vepřové mleté maso z plece s obsahem tuku

15% z Masozávodu Modletice, vepřové mleté maso s obsahem tuku 30% z Masozávodu Modletice a kuřecí mleté maso stehenní z Drůbežářského závodu Klatovy a.s.

		Měření č. 1				
		Typ masa	H	K	V15	V30
SID	H		0	30,18	29,29	45,03
	K		30,18	0	2,37	33,15
	V15		29,29	2,37	0	20,28
	V30		45,03	33,15	20,28	0
SAM	H		0	0,16	0,15	0,16
	K		0,16	0	0,04	0,11
	V15		0,15	0,04	0	0,08
	V30		0,16	0,11	0,08	0
SIDSAM	H		0	4,79	4,49	7,03
	K		4,79	0	0,09	3,50
	V15		4,49	0,09	0	1,60
	V30		7,03	3,50	1,60	0

Tabulka 5.3: Měření č. 1: H - hovězí, K - kuřecí, V15 - vepřové 15% tuku, V30 - vepřové 30% tuku




Obrázek 5.8: Měření č. 1: porovnání spektrálních metrik

Můžeme si na výsledcích na obrázku 5.8 a v tabulce 5.3 povšimnout podobnosti spekter kuřecího masa s vepřového masa s 15% tuku. Domnívám se, že tato skutečnost mohla nastat kvůli datu spotřeby kuřecího mletého masa. Spotřeba tohoto masa končila v den měření.

Měření č. 2 bylo provedeno se vzorky mletého masa kuřecího stehenního z Drůbežářského závodu Klatovy a.s., vepřového mletého masa 100% od Kosteleckých uzenin a.s., hovězího mletého masa 100% také od Kosteleckých uzenin a.s.. Poslední typ vzorku bylo kuřecí mleté maso, které bylo namleto doma z kuřecích nudliček z prsních řízků z Drůbežářského závodu Klatovy a.s.

		Měření č. 2				
		Typ masa	KK	V	H	KD
SID	KK	0	9,72	61,45	5,76	
	V	9,72	0	40,34	20,69	
	H	61,45	40,34	0	94,84	
	KD	5,76	20,69	94,84	0	
SAM	KK	0	0,09	0,18	0,06	
	V	0,09	0	0,12	0,13	
	H	0,18	0,12	0	0,22	
	KD	0,06	0,13	0,22	0	
SIDSAM	KK	0	0,86	11,04	0,35	
	V	0,86	0	4,78	2,70	
	H	11,04	4,78	0	21,46	
	KD	0,35	2,70	21,46	0	

Tabulka 5.4: Měření č. 2: KK - kuřecí kouspené, V - vepřové, H - hovězí, KD - kuřecí domácí



Obrázek 5.9: Měření č. 2: porovnání spektrálních metrik

Jak je patrné v tabulkách (5.3) a (5.4), tak při použití různých spektrálních metrik jsme schopni rozlišit jednotlivé druhy mletých mas. Důvodem je, že každý typ mletého masa odráží jiné vlnové délky. Například při porovnání kuřecího mletého masa s hovězím mletým masem je vidět, že hovězí má několikrát větší odrazivost než kuřecí. Naopak pokud porovnáme spektrální charakteristiky stejných typů mletých mas, například vepřového s 15% tuku a vepřového s 30% tuku z měření č. 1 nebo kuřecího kupovaného s kuřecím domácím mletým masem z měření č. 2, dojdeme k závěrům, že jejich spektrální charakteristiky jsou velmi podobné. Slabou odlišnost u spektrálních charakteristik vepřových mletých mas z měření č. 1 můžeme vysvětlit různým obsahem tuku. Vepřové mleté maso s 30% obsahu tuku má větší odrazivost než s 15%, jak můžeme vidět v tabulce (5.3).

Dále byla z obou měření vzata data stejných typů mletých mas a ta byla porovnána mezi sebou třemi spektrálními metrikami.

		Kuřecí maso								
		SID			SAM			SIDSAM		
Typ masa	K1	K2	KD	K1	K2	KD	K1	K2	KD	
K1	0	14,97	32,22	0	0,11	0,16	0	1,72	5,29	
K2	14,97	0	4,90	0,11	0	0,05	1,72	0	0,27	
KD	32,22	4,90	0	0,16	0,05	0	5,29	0,27	0	

Tabulka 5.5: Kuřecí mleté maso: K1 - kuřecí kouskové z měření č.1, K2 - kuřecí kouskové z měření č.2, KD - kuřecí domácí z měření č.2


		Hovězí maso					
		SID		SAM		SIDSAM	
Typ masa	H1	H2	H1	H2	H1	H2	
H1	0	37,66	0	0,12	0	4,48	
H2	37,66	0	0,12	0	4,48	0	

Tabulka 5.6: Hovězí mleté maso: H1 - hovězí z měření č. 1, H2 - hovězí z měření č. 2

		Vepřové maso								
		SID			SAM			SIDSAM		
Typ masa	V	V15	V30	V	V15	V30	V	V15	V30	
V	0	3,30	16,18	0	0,05	0,07	0	0,17	1,21	
V15	3,30	0	19,26	0,05	0	0,08	0,17	0	1,49	
V30	16,18	19,26	0	0,07	0,08	0	1,21	1,49	0	

Tabulka 5.7: Vepřové mleté maso: V - vepřové z měření č.2, V15 - vepřové s 15% tuku z měření č.1, V30 - vepřové s 30% tuku z měření č.1

Poslední provedená analýza se vzorky masa, bylo porovnání referenčního spektra se spektrem testovaným. Tato analýza byla provedena na vzorku masa z měření č. 2 a byly v něm použity vzorky kuřecího mletého masa domácího, hovězího mletého masa a vepřového mletého masa (viz. 5.5). V tomto vzorku nebyly jasně rozděleny hranice a všechna masa byla smíchána. Cílem bylo, zda pomocí reflektancí budeme schopni rozpoznat různé druhy mletého masa ve smíchaném vzorku (Obrázek: 5.10).




Obrázek 5.10: Rozdělení masa ve vzorku

Jak si můžeme povšimnout na obrázku (5.10) jednotlivé druhy masa jdou pomocí hyperspektrálního snímání dobře rozeznat i přes fakt, že jsou různé typy mas smíchány dohromady. Nejlépe jsou rozdíly vidět pomocí spektrální metriky SAM s nastavením threshold na 0,08.

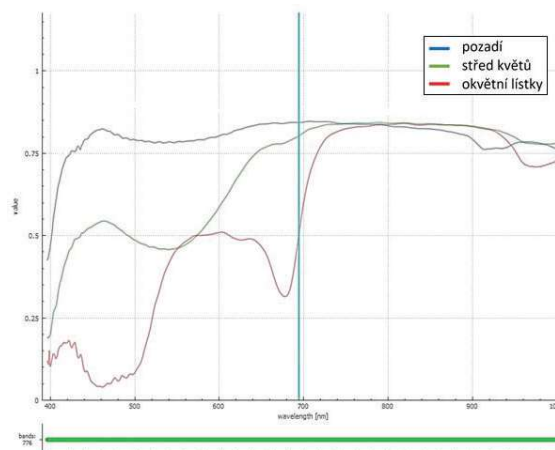
5.3.2 Rostliny

Dalším zkoumaným biologickým vzorkem byly různé druhy rostlin. Přesněji byly vybrány dva květy dvou různých stromů Sakury ozdobné (*Prunus serrulata*), poté vzorek Sedmikrásky chudobky (*Bellis perennis*) a různé typy a barvy okvětních lístků tulipánů: Rembrandtovy tulipány - žluto-červený, fialovo-bílý, bílo-fialový, fialový a zahradní tulipán červený .

Vzorek Sedmikrásky chudobky byl nasnímán hyperspektrální kamerou a poté vložen do programu perClass MIRA. Byly vytvořeny tři třídy: pozadí, okvětní lístky a střed květů (Obrázek:5.11a). Z jednotlivých částí byl vytvořen graf reflektance (Obrázek: 5.11b).



(a) Květ sedmikrásky chudobky




(b) Reflektance

Obrázek 5.11: Sedmikráska a reflektance jejích částí

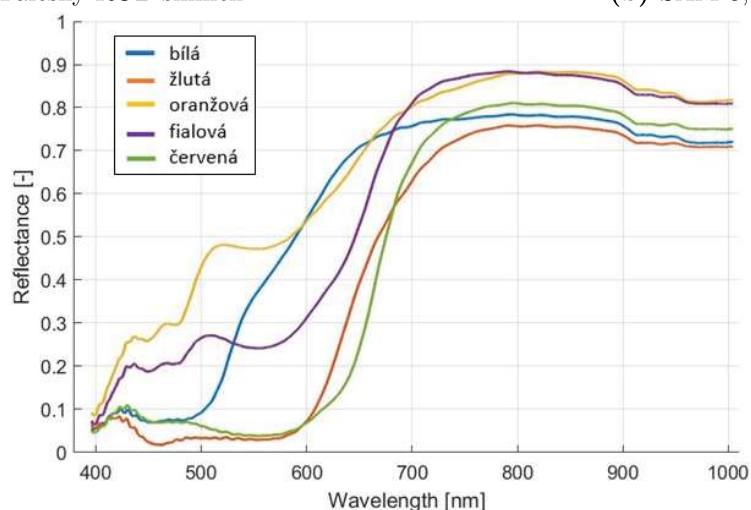
Květy Sakury ozdobné a okvětní lístky tulipánů byly vyhodnoceny pomocí programu HyperCalib v MATLAB. U květů sakury dopadla analýza velmi podobně, ikdyž každý květ pocházel z jiného stromu (Obrázek: 5.13). Spektrální charakteristiky těchto květů se velmi podobaly. Pro okvětní listy tulipánů byla použita spektrální metrika SAM. Ta dokázala odlišit jednotlivé barvy vzorků. Třeba fialová barva byla u posledních třech vzorků rozlišena velmi dobře.



(a) Falešný RGB snímek




(b) SAM 0,05



(c) Reflektance

Obrázek 5.12: Okvětní lístky tulipánů a jejich analýza pomocí SAM



(a) Falešný RGB snímek květů sakury

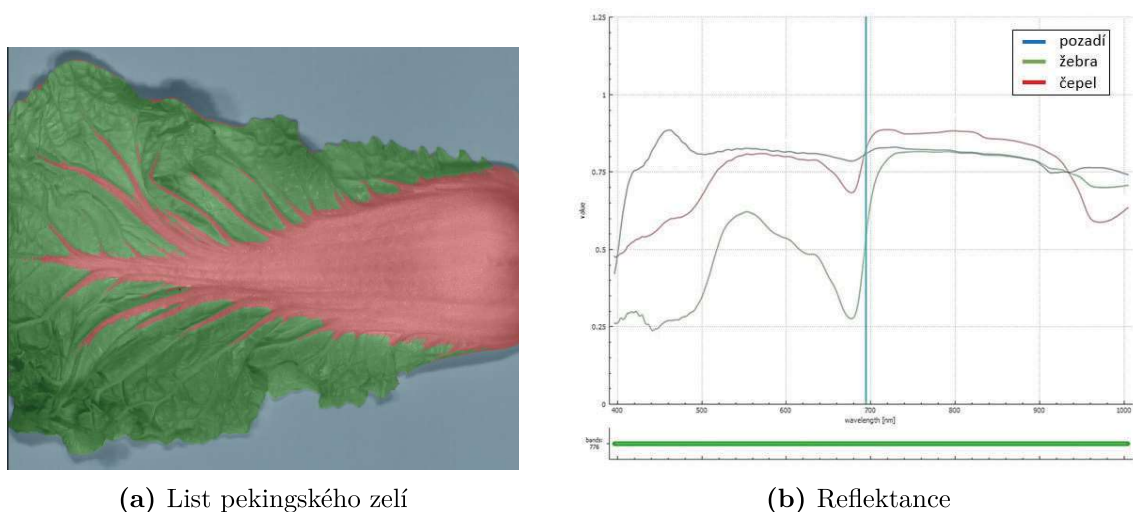
(b) SIDSAM 5

Obrázek 5.13: Květy sakury a použití spektrální metriky SIDSAM

5.3.3 Potraviny

V datovém setu se nacházejí i další vzorky z oblasti potravin kromě mletého masa jako zelenina, ovoce či ořechy. Všechny nasnímané vzorky, které budou níže zmíněny byly analyzovány pomocí programu perClass Mira.

Z oblasti zeleniny byl nasnímán hyperspektrální kamerou list Pekingského zelí. V programu perClass Mira byla odlišena bělavá žebra listu od jeho zelené čepele pomocí tříd a bylo zadefinováno pozadí. Následně program vypočetl model a zvýraznil jednotlivé části listu, pro které vytvořil spektrální charakteristiku (Obrázek: 5.14).



(a) List pekingského zelí


(b) Reflektance

Obrázek 5.14: List pekingského zelí při oddělení natě a zelené části a reflektance: modrá - pozadí, zelená - zelená čepele, červená - žebra


Velmi podobný postup analýzy byl aplikován na okurku salátovou, kde byla snaha odlišit část se slupkou a bez slupky (Obrázek: 5.15). Důvodem této analýzy byla studie (viz. 4.3.3) zabývající se defekty okurek. Porovnání dokázalo, že spektrální charakteristiky okurky salátové se slupkou a bez slupky jsou rozdílné.

Nasnímán byl dále pomeranč s citronem, kde byla snaha odlišit dužinu a slupku u obou vzorků a porovnat jejich reflektance (Obrázek: 5.16).

Posledním vzorkem jsou pistácie, kde jsem zkoumala zda analýza prokáže, co je skořápka a co je samotný ořech (Obrázek: 5.17).




(a) Salátová okurka se slupkou a bez

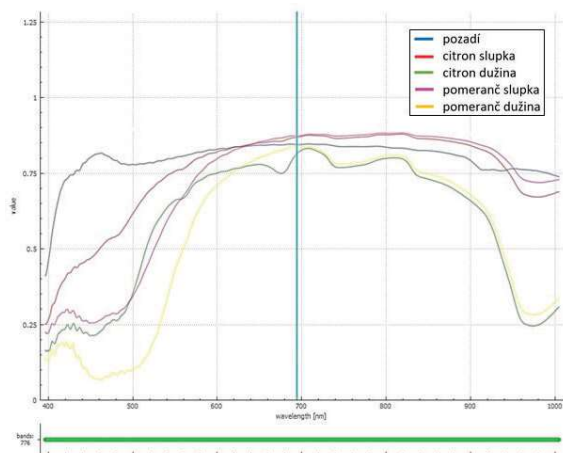


(b) Reflektance

Obrázek 5.15: Salátová okurka a rozpoznání částí se slupkou a bez a jejich reflektance: modrá - pozadí, zelená - slupka, červená - dužina




(a) Citrusy: A - citron, B - pomeranč




(b) Reflektance

Obrázek 5.16: Citrusy a rozpoznání dužiny od slupky a jejich reflektance: modrá - pozadí, zelená a žlutá - dužina, červená a fialová - slupka



(a) Pistácie a rozdění skořápky od ořechu



(b) Reflektance

Obrázek 5.17: Pistácie a oddělení ořechu od skořápky a jejich reflektance: modrá - pozadí, zelená - skořápka, červená - oříšek

Závěr

Hyperspektrální snímání je poměrně novou metodou, která se stále vyvíjí a nalézá své využití v mnoha různých odvětvích. Tato bakalářská práce se zabývala především oblastí biologie.

V prvních kapitolách byl zmíněn teoretický úvod a vysvětlen princip hyperspektrálního snímání s následnou analýzou hyperspektrálních dat. Byly popsány algoritmy pro analýzu těchto dat.

Ve čtvrté kapitole byl vytvořen přehled aplikací hyperspektrálního snímání v biologii. Nalezneme ho například v medicíně při detekci různých chorob nebo při operacích. Dále je používáno v potravinářském průmyslu pro kontrolu kvality potravin. Zajímavé použití může mít hyperspektrální snímání při kontrole v masném průmyslu. K tomuto účelu bylo provedeno několik studií, kde některé prokázaly zajímavé vlnové délky pro různé druhy mas. Tento poznatek může být použit při kontrole masa proti falzifikaci. Kromě masa bylo hyperspektrální snímání použito i pro průzkum ryb, zeleniny, ovoce nebo ořechů. Původním záměrem hyperspektrálního snímání byl dálkový průzkum Země, který probíhá i do dnešních dnů.

Pátá kapitola se zaměřuje na praktickou část bakalářské práce. V úvodu této kapitoly je popsána hyperspektrální kamera Specim PFD4K-65-V10E a její příslušenství. Ta byla použita pro snímání biologických vzorků. Výběr biologických vzorků byl ovlivněn studiemi popsanými ve čtvrté kapitole. V datovém setu se nacházejí vzorky různých rostlin a potravin. Reflektance biologických vzorků byly vytvořeny pomocí dvou programů. Na některé vzorky byly použity spektrální metriky (SID, SAM, SIDSAM), které rozeznaly odlišnosti spekter vzorků. Nejvíce se práce zaměřila na porovnání různých druhů mletého masa: vepřové, hovězí či kuřecí. Dalšími nasnímanými vzorky z kategorie potravin byly odlišné typy zeleniny nebo ovoce. Momentální nevýhodou hyperspektrálního snímání je jeho pořizovací cena, která ho činí pro průmysl nepoužitelným. Snaha je pomocí hyperspektrálního snímání nalézt nejvhodnější vlnové délky, jež by se daly použít v multispektrálních přístrojích. Kromě potravinářských vzorků byly nasnímany květy různých druhů rostlin, jako je sakura okrasná nebo odlišné druhy tulipánů. Na tyto květy, popřípadě okvětní lístky, byly také aplikovány spektrální metriky či jiné algoritmy vyhodnocující podobnost jejich spektrálních charakteristik.

Hyperspektrální snímání má velkou budoucnost pro využití v dalších odvětvích. Toto téma není ještě tolik prozkoumané, ale v poslední době se začíná více využívat. V práci jsem se snažila poukázat, že hyperspektrální snímání může najít své velké využití i v biologických aplikacích.

Bibliografie

1. LEPIL, Oldřich; KUPKA, Zdeněk. *Fyzika: pro gymnázia. Optika*. Praha: Prometheus, 2021. ISBN 978-80-7196-444-5.
2. REICHL, Jaroslav; VŠETIČKA, Martin et al. Encyklopedie fyziky. 2006. Dostupné také z: <http://fyzika.jreichl.com/>.
3. KULHÁNEK, Petr. *Tabulky → spektrum*. 2008. Dostupné také z: https://www.aldebaran.cz/tabulky/tb_spektrum.php.
4. HALLIDAY, David; RESNICK, Robert; WALKER, Jearl. *Fundamentals of physics*. John Wiley & Sons, 2018. ISBN 9781119460138.
5. HARTMANN, Petr. *Kompresní metody pro hyperspektrální zobrazování*. 2019. Dipl. pr. České vysoké učení technické v Praze. Vypočetní a informační centrum.
6. KITTNAR, Otomar et al. *Lékařská fyziologie: 2., přepracované a doplněné vydání*. Praha: Grada Publishing, as, 2020. ISBN 978-80-247-1963-4.
7. SINĚLNIKOV, Rafail Davidovič. *Atlas anatomie člověka. 3. díl: Nauka o nervové soustavě, o ústrojích smyslových a o žlázách s vnitřní sekrecí*. Praha: Avicenum, 1982.
8. ČIHÁK, Radomír. *Anatomie 3: Třetí, upravené a doplněné vydání*. Praha: Grada Publishing as, 2016. ISBN 978-80-247-5636-3.
9. HUDÁK, Radovan; KACHLÍK, David. *Memoria anatomie*. 5. vydání. Praha: Triton, 2021. ISBN 978-80-7553-873-4.
10. VADIVAMBAL, Rajagopal; JAYAS, Digvir S. *Bio-imaging: principles, techniques, and applications*. CRC Press, 2018. ISBN 9781138749634.
11. KRAUZ, Lukáš; PÁTA, Petr; KAISER, Jan. Assessing the Spectral Characteristics of Dye-and Pigment-Based Inkjet Prints by VNIR Hyperspectral Imaging. *Sensors*. 2022, roč. 22, č. 2, s. 603. Dostupné z DOI: 10.3390/s22020603.
12. ADÃO, Telmo; HRUŠKA, Jonáš; PÁDUA, Luís; BESSA, José; PERES, Emanuel; MORAIS, Raul; SOUSA, Joaquim Joao. Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote sensing*. 2017, roč. 9, č. 11, s. 1110. Dostupné z DOI: 10.3390/rs9111110.
13. AMIGO, Jose Manuel. *Hyperspectral imaging*. Elsevier, 2019. ISBN 9780444639783.
14. GRAHN, Hans; GELADI, Paul. *Techniques and applications of hyperspectral image analysis*. John Wiley & Sons, 2007. ISBN 978-0-470-01086-0.

15. 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. Dostupné z DOI: 10.1117/1.JBO.18.10.100901.
16. GOWEN, Aoife A; O'DONNELL, Colm P; CULLEN, Patrick J; DOWNEY, Gérard; FRIAS, Jesus M. Hyperspectral imaging—an emerging process analytical tool for food quality and safety control. *Trends in food science & technology*. 2007, roč. 18, č. 12, s. 590–598. Dostupné z DOI: 10.1016/j.tifs.2007.06.001.
17. 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.
18. KRUSE, Fred A; LEFKOFF, AB; BOARDMAN, JW; HEIDEBRECHT, KB; SHAPIRO, AT; BARLOON, PJ; GOETZ, AFH. The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data. *Remote sensing of environment*. 1993, roč. 44, č. 2-3, s. 145–163. Dostupné z DOI: 10.1016/0034-4257(93)90013-N.
19. DU, Yingzi; CHANG, Chein-I; REN, Hsuan; CHANG, Chein-Chi; JENSEN, James O; D'AMICO, Francis M. New hyperspectral discrimination measure for spectral characterization. *Optical engineering*. 2004, roč. 43, č. 8, s. 1777–1786. Dostupné z DOI: 10.1117/1.1766301.
20. HEARST, Marti A.; DUMAIS, Susan T; OSUNA, Edgar; PLATT, John; SCHOLKOPF, Bernhard. Support vector machines. *IEEE Intelligent Systems and their applications*. 1998, roč. 13, č. 4, s. 18–28. ISBN 978-0-387-77241-7.
21. CORTES, Corinna; VAPNIK, Vladimir. Support-vector networks. *Machine learning*. 1995, roč. 20, č. 3, s. 273–297. Dostupné z DOI: 10.1023/A:1022627411411.
22. SHLENS, Jonathon. A tutorial on principal component analysis. *arXiv preprint arXiv:1404.1100*. 2014. Dostupné z DOI: 10.48550/arXiv.1404.1100.
23. CHANG, Chein-I. *Hyperspectral data processing: algorithm design and analysis*. John Wiley & Sons, 2013. ISBN 978-0-471-69056-6.
24. CLARK, RN; KING, TVV; AGER, C; GA, Swayze. Initial vegetation species and senescence/stress mapping in the San Louis Valley, Colorado using imaging spectrometry data, Posey, HH, Pendleton, JA, and Van Zyl, D. In: *Proceedings: Summitville Forum '95, Colorado Geological Survey Spec. Publ.* 1995, sv. 38, s. 59–63. ISBN 978-1884216510.
25. DWIVEDI, RS; RAO, BRM. The selection of the best possible Landsat TM band combination for delineating salt-affected soils. *International Journal of Remote Sensing*. 1992, roč. 13, č. 11, s. 2051–2058. Dostupné z DOI: 10.1080/01431169208904252.
26. BORENGASSER, Marcus; HUNGATE, William S; WATKINS, Russell. *Hyperspectral remote sensing: principles and applications*. CRC press, 2007. ISBN 9781138747180.

27. PATEL, NK; PATNAIK, C; DUTTA, S; SHEKH, AM; DAVE, AJ. Study of crop growth parameters using airborne imaging spectrometer data. *International Journal of Remote Sensing*. 2001, roč. 22, č. 12, s. 2401–2411. Dostupné z DOI: 10.1080/01431160117383.
28. SICILIANO, Daria; WASSON, Kerstin; POTTS, Donald C; OLSEN, RC. Evaluating hyperspectral imaging of wetland vegetation as a tool for detecting estuarine nutrient enrichment. *Remote Sensing of Environment*. 2008, roč. 112, č. 11, s. 4020–4033. Dostupné z DOI: 10.1016/j.rse.2008.05.019.
29. DICKER, David T; LERNER, Jeremy; VAN BELLE, Pat; GUERRY 4th, DuPont; HERLYN, Meenhard; ELDER, David E; EL-DEIRY, Wafik S. Differentiation of normal skin and melanoma using high resolution hyperspectral imaging. *Cancer biology & therapy*. 2006, roč. 5, č. 8, s. 1033–1038. Dostupné z DOI: 10.4161/cbt.5.8.3261.
30. JOHNSON, William R; WILSON, Daniel W; FINK, Wolfgang; HUMAYUN, Mark S; BEARMAN, Gregory H. Snapshot hyperspectral imaging in ophthalmology. *Journal of biomedical optics*. 2007, roč. 12, č. 1, s. 014036. Dostupné z DOI: 10.1117/1.2434950.
31. LEMMENS, Sophie; VAN EIJGEN, Jan; VAN KEER, Karel; JACOB, Julie; MOYLETT, Sinéad; DE GROEF, Lies; VANCRAENENDONCK, Toon; DE BOEVER, Patrick; STALMANS, Ingeborg. Hyperspectral imaging and the retina: worth the wave? *Translational vision science & technology*. 2020, roč. 9, č. 9, s. 9–9. Dostupné z DOI: 10.1167/tvst.9.9.9.
32. PÍTHOVÁ, Pavlína. Syndrom diabetické nohy–možnosti diagnostiky a léčby. *Praktické lékařství*. 2010, roč. 6, č. 3, s. 130–133. Dostupné také z: https://www.praktickelekarenstvi.cz/artkey/lek-201003-0006_Syndrom_diabeticke_nohy-moznosti_diagnostiky_a_lecby.php.
33. BASANTIA, NC; NOLLET, Leo ML; KAMRUZZAMAN, Mohammed. *Hyperspectral Imaging Analysis and Applications for Food Quality*. CRC Press, 2018. ISBN 9781138630796.
34. KAMRUZZAMAN, Mohammed; MAKINO, Yoshio; OSHITA, Seiichi. Parsimonious model development for real-time monitoring of moisture in red meat using hyperspectral imaging. *Food chemistry*. 2016, roč. 196, s. 1084–1091. Dostupné z DOI: 10.1016/j.foodchem.2015.10.051.
35. KAMRUZZAMAN, Mohammed; SUN, Da-Wen; ELMASRY, Gamal; ALLEN, Paul. Fast detection and visualization of minced lamb meat adulteration using NIR hyperspectral imaging and multivariate image analysis. *Talanta*. 2013, roč. 103, s. 130–136. Dostupné z DOI: 10.1016/j.talanta.2012.10.020.
36. KAMRUZZAMAN, Mohammed; MAKINO, Yoshio; OSHITA, Seiichi. Hyperspectral imaging for real-time monitoring of water holding capacity in red meat. *LWT-Food Science and Technology*. 2016, roč. 66, s. 685–691. Dostupné z DOI: 10.1016/j.lwt.2015.11.021.
37. CHENG, Jun-Hu; SUN, Da-Wen. Data fusion and hyperspectral imaging in tandem with least squares-support vector machine for prediction of sensory quality index scores of fish fillet. *LWT-Food Science and Technology*. 2015, roč. 63, č. 2, s. 892–898. Dostupné z DOI: 10.1016/j.lwt.2015.04.039.

38. DACAL-NIETO, Angel; FORMELLA, Arno; CARRIÓN, Pilar; VAZQUEZ-FERNANDEZ, Esteban; FERNÁNDEZ-DELGADO, Manuel. Non-destructive detection of hollow heart in potatoes using hyperspectral imaging. In: *International Conference on Computer Analysis of Images and Patterns*. 2011, s. 180–187.
39. PARK, Bosoon; LU, Renfu. *Hyperspectral imaging technology in food and agriculture*. Springer, 2015. ISBN 978-1-4939-2835-4.
40. RŮŽIČKA, Miroslav. *Parametry hyperspektrálních snímacích systémů*. 2021. Dipl. pr. České vysoké učení technické v Praze. Vypočetní a informační centrum.
41. DE LA VEGA, Susi Huamán; MANIAN, Vidya. Object segmentation in hyperspectral images using active contours and graph cuts. *International journal of remote sensing*. 2012, roč. 33, č. 4, s. 1246–1263. Dostupné z DOI: 10.1080/01431161.2011.560208.

Přílohy

A První příloha

Na přiloženém DVD se nachází složka s jedním vybraných hyperspektrálním obrázkem z nasnímaných dat. Zbytek všech nasnímaných dat se nachází na katedře radioelektroniky FEL ČVUT, kvůli nadměrné velikosti dat. Soubory jsou na DVD rozděleny do jednotlivých sekcí.

A.1 mletemaso_2022-04-19_09-28-31

Výstupní soubory nasnímaného mletého masa z hyperspektrální kamery.

- calibrations
- capture
 - DARKREF_mletemaso_2022-04-19_09-28-31.raw - tmavý snímek pro referenci
 - mletemaso_2022-04-19_09-28-31.raw - snímek vzorku
 - WHITEREF_mletemaso_2022-04-19_09-28-31.raw - bílý snímek pro referenci
- metadata
- manifest.xml
- mletemaso_2022-04-19_09-28-31.png
- properties.xml

A.2 MATLAB

Obsahuje veškeré soubory použité při výpočtu odlišností spektrálních metrik nasnímaných vzorků v prostředí MATLAB. Označení ref1 je pro vzorky z měření č.1, označení ref2 je pro vzorky z měření č.2.

- maso-ref1.mat
- maso-ref1-hovez.mat
- maso-ref1-kure.mat
- maso-ref1-vepr.mat
- maso-ref2.mat
- maso-ref2-hovez.mat
- maso-ref2-kure.mat
- maso-ref2-vepr.mat

A.3 Vyhodnoceni_metrik

V této složce se nacházejí snímky různých nastavení všech spektrálních metrik na nasnímaných datech. Snímky jsou popsány typem spektrální metriky, zvolený práh a typ nasnímaného vzorku.

- m1_mix_SAM_0.08.jpg
- m1_mix_SID_20.jpg
- m1_mix_SIDSAM_1.jpg
- m1_vepr_ref.jpg
- m2_kure_ref.jpg
- maso_ref_SAM_0.07.jpg
- maso_ref_SID_15.jpg
- maso_ref2_SAM_0.05.jpg
- maso_ref2_SAM_0.07.jpg
- maso_ref2_SAM_0.08.jpg
- maso_ref2_SID_15.jpg
- maso_ref2_SID_17.jpg
- maso_ref2_SID_20.jpg
- maso_ref2_SS_0.8.jpg
- maso_ref2_SS_1.jpg
- maso_ref2_SS_2.jpg
- maso_ref2_SS_5.jpg
- pistacie_SAM_0.15.jpg
- pistacie_SID_35.jpg
- pistacei_SIDSAM_5.jpg
- sakura_ref.jpg
- tulipan_mix_SID_15.jpg