

# **Moderní metody detekce a extrakce příznaků optického disku z retinálních obrazů**

Modern Methods of Detection and Features Extraction of  
Optical Disc from Retinal Images

**Bc. Markéta Malá**

Diplomová práce

Vedoucí práce: Ing. Jan Kubíček, Ph. D.

Ostrava 2023

## Zadání diplomové práce

Student: **Bc. Markéta Malá**

Studijní program: N0988A060001 Biomedicínské inženýrství

Téma: **Moderní metody detekce a extrakce příznaků optického disku z  
retinálních obrazů**  
**Modern Methods of Detection and Features Extraction of Optical Disc  
from Retinal Images**

Jazyk vypracování: čeština

Zásady pro vypracování:

Anotace:

Analýza optického disku z retinálních obrazů patří k základním úkonům, které se řeší v rámci klinické diagnostiky. V tomto kontextu nabývají na důležitosti automatizované metody pro detekci a identifikaci optického disku z retinálních obrazů. Cílem diplomové práce je analýza a rozsáhlé testování vybraných automatizovaných metod segmentace obrazu pro detekci optického disku a kvantifikaci jeho příznaků. V rámci diplomové práce se předpokládá vytvoření objektivizační analýzy efektivity a robustnosti metod segmentace pro datové báze, obsahující jak retinální obrazy dospělých pacientů, tak nedonošených dětí s cílem evaluace robustnosti analyzovaných metod pro variabilní obrazová data. Součástí práce je rovněž vytvoření softwarového prostředí, které integruje metody pro detekci optického disku a umožňuje tvorbu a evaluaci segmentačních modelů.

Body zadání práce:

1. Nastudování zobrazovacích metod pro diagnostiku očního pozadí.
2. Nastudování metod regionální segmentace pro identifikaci objektů z medicínských obrazů.
3. Rešerše metod pro identifikaci optického disku z retinálních obrazů.
4. Analýza retinálních dat z variabilních zobrazovacích modalit.
5. Návrh a implementace segmentačních metod pro detekci optického disku.
6. Testování efektivity a robustnosti detekce navržených metod na základě extrahovaných příznaků optického disku.
7. Tvorba SW rozhraní pro integraci metod detekce optického disku.
8. Diskuse a objektivní vyhodnocení výsledků práce.

Seznam doporučené odborné literatury:

1. BRUCE, Eugene N. Biomedical signal processing and signal modeling. New York: Wiley, c2001. Wiley series in telecommunications and signal processing. ISBN 0-471-34540-7.
2. KRAUS, Hanuš. Kompendium očního lékařství. Praha: Grada Publishing. ISBN 80-7169-079-1.
3. BIRKFELLNER, Wolfgang. Applied medical image processing: a basic course. 2nd ed. Boca Raton: CRC Press, c2014. ISBN 978-1-4665-5557-0.

4. JAN, Jiří. Medical image processing, reconstruction and restoration: concepts and methods. Boca Raton: Taylor & Francis, 2006. Signal processing and communications, 25. ISBN 0-8247-5849-8.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Jan Kubiček, Ph.D.**

Datum zadání: 01.09.2022

Datum odevzdání: 30.04.2023

Garant studijního programu: prof. Ing. Marek Penhaker, Ph.D.

V IS EDISON zadáno: 16.11.2022 07:15:58

### **Poděkování**

Ráda bych poděkovala mému vedoucímu práce panu Ing. Janu Kubíčkoví, Ph. D. za jeho cenné rady, připomínky, odborné konzultace a hlavně vstřícnost při vytváření této diplomové práce.

## Abstrakt

Diplomová práce se zabývá testováním metod automatické segmentace pro detekci optického disku. Pro analýzu se využívaly datasety Clarity RetCam 3, Envision RetCam 3, Phoenix ICON, Data Drive a Data Stare. Celkově bylo zpracováno 232 snímků sítnice dospělých pacientů a dětí s onemocněním Retinopatie nedonošených (ROP). Počáteční částí bylo manuální zpracování obrázků, kde výsledkem byl zlatý standard. Klíčovou částí byl návrh algoritmů pro zpracování obrazových dat. Nejprve byl obraz předzpracován s využitím metody CLAHE a Bilaterálního filtru. Aktivní kontury bez hran tvořily algoritmus segmentace. Metoda využívala volně se deformovatelných křivek. Výsledkem byl binární obraz, který se porovnával se zlatým standardem. Rozdílnosti mezi metodami byly vyhodnocovány pomocí evaluačních parametrů. Došlo tak ke zhodnocení efektivitě metod segmentace pro různé zobrazovací modality. Na závěr bylo vytvořeno grafické uživatelské rozhraní pomocí programu MATLAB.

## Klíčová slova

Optický disk, fundus kamera, předzpracování obrazu, segmentace obrazu, metoda aktivních kontur

## Abstract

The master thesis focused on testing the methods of automatic segmentation for detection of optical disc. Datasets Clarity RetCam 3, Envision RetCam 3, Phoenix ICON, Data Drive and Data Stare was used for the analysis. Altogether, 232 images of retina of adult patients and children diagnosed with retinopathy of prematurity (ROP) were analyzed. The first part was a manual processing of the images, where the golden standard came as a result. The core part was a proposal of algorithms for processing the data images. Firstly, an image was preprocessed using the method CLAHE and Bilateral filter. Active contours without the edges were used to make the segmentation algorithm. The method used freely deformed curves. The result received from this action was a binar image, wich was then compared to the golden standard. The differences between the methods were evaluated based on the evauation parameters. Therefore, the effecivity of methods of segmentation for different displaying modalities were evaluated. Finally, the graphical user interface (GUI) was made in the MATLAB program.

## Key words

Optical disc, fundus cam, image preprocessing, image segmentation, active contour method

# Obsah

Seznam použitých symbolů a zkratk.....	6
Seznam ilustrací.....	7
Seznam tabulek.....	9
Úvod.....	10
1. Zobrazovací metody pro diagnostiku očního pozadí.....	11
1.1 Oftalmoskop.....	11
1.1.1 Princip oftalmoskopu.....	12
1.2 Štěrbinová lampa.....	13
1.2.1 Princip štěrbinové lampy.....	14
1.3 Fundus kamera.....	14
1.3.1 Konstrukce fundus kamery.....	15
1.3.2 Princip fundus kamery.....	15
1.4 Optická koherenční tomografie (OCT).....	16
1.4.1 Konstrukce OCT.....	16
1.4.2 Princip OCT.....	17
1.4.3 Topografická mapa.....	19
1.5 Heidelberský retinální tomograf (HRT).....	22
1.5.1 Princip HRT.....	22
2. Segmentace obrazu.....	24
2.1 Rozdělení segmentace.....	25
2.1.1 Detekce hran.....	25
2.1.2 Prahování - Tresholding.....	27
2.1.3 Segmentace podle regionů.....	28
3. Rešerše metod pro identifikaci optického disku.....	33
3.1 Segmentace na základě biregionální konstrukce.....	34
3.2 Segmentace optického disku prahováním.....	37
3.3 Segmentace optického disku detekcí hran.....	37
3.4 Segmentace na základě strukturovaného učení.....	38
4. Analýza retinálních dat z variabilních zobrazovacích modalit.....	42
5. Návrh algoritmu pro detekci optického disku.....	45
5.1 Manuální anotace optického disku.....	46
5.2 Předzpracování obrazu.....	48
5.2.1 Výběr chromizační složky.....	48

5.2.2 Monochromatické operace .....	49
5.2.3 Ekvalizace histogramu .....	50
5.2.4 Jasová transformace.....	53
5.2.5 Filtrace obrazu.....	54
5.3 Automatická segmentace optického disku .....	55
5.3.1 Aktivní kontury bez hran .....	55
5.3.2 Binarizace obrazu .....	59
6 Testování efektivity a evaluace robustnosti detekce pro variabilní obrazová data .....	62
6.1 Analýza podobnosti modelu optického disku .....	62
6.2 Evaluační parametry po vyhodnocení výkonu segmentace .....	63
6.3 Evaluace robustnosti analyzovaných metod .....	65
7. Návrh softwarového rozhraní .....	73
8. Diskuse a objektivní vyhodnocení výsledků .....	77
Závěr .....	79
Seznam příloh.....	84

## Seznam použitých symbolů a zkratek

OCT	Optická koherentní tomografie (optical coherence tomograph)
IR	Infračervené záření
2D	Dvourozměrný obraz
3D	Třírozměrný obraz
TD OCT	Time domain OCT
SD OCT	Spectral domain OCT
FD OCT	Fourier domain OCT
SLD	Superluminiscenční dioda
ROI	Objekt zájmu (Region of Interest)
Mpix	Megapixel
Fps	Jednotka snímkové frekvence (frames per second)
FullHD	Velikost a kvalita přenášeného videa (1080p)
RF	Světlo bez červené barvy (red free light)
VPMD	Věkem podmíněná makulární degenerace
RNFL	Tloušťka vrstvy nervových vláken sítnice (retinal nerve fiber layer)
HRT	Heidelberský retinální tomograf
TZN	Terč zrakového nervu
C	Exkavace, pohárek (cup)
D	Terč (disc)
OD	Optický disk (optic disc)
OC	Optická exkavace, pohárek (optic cup)
CCD	Snímače pro zpracování obrazu (charge coupled device)
FCM	Fuzzy C - Means
BCFCM	Shlukovací algoritmy (bias corrected FCM)
ILM	Vnitřní limitující membrány (inner limiting membrane)
RPE	Pigmentový epitel (retinal pigment epithelium)
MRF	Markova náhodná pole (Markova náhodná pole)
ROI	Oblast zájmu (region of interest)
BCE	Biregionální evoluce kontur (biregional contour evolution)
CDR	Poměr pohárku k disku (cup to disc ratio)
ROP	Retinopatie nedonošených
AHE	Adativní ekvalizace histogramu
CLAHE	Kontrastně limitovaná adaptivní ekvalizace histogramu
CDF	Kumulativní distribuční funkce
BF	Bilaterální filtr
LGDF	Lokální Gaussova distribuční funkce
GUI	Grafické uživatelské rozhraní



## Seznam ilustrací

Obrázek 1. Oftalmoskop [vlastní] .....	12
Obrázek 2. a) Štěrbínová lampa Haag Streit, b) Štěrbínová lampa typu Zeiss [vlastní] .....	13
Obrázek 3. Fundus kamera [4] .....	14
Obrázek 4. Snímek sítnice zachycený fundus kamerou [vlastní] .....	15
Obrázek 5. OCT s počítačovou jednotkou [vlastní] .....	17
Obrázek 6. Princip TD OCT [upraveno podle 16] .....	18
Obrázek 7. Princip SD OCT [upraveno podle 16] .....	19
Obrázek 8. Horizontální řez vrstev sítnice [vlastní] .....	21
Obrázek 9. Vrstva nervových vláken a terč zrakového nervu [vlastní] .....	21
Obrázek 10. Modely ideální hrany: a) skoková, b) střecha, c) šikmá, d) linie [upraveno podle 26] .....	26
Obrázek 11. Směr hrany $\varphi$ kolmý na směr gradientu $\psi$ [25] .....	27
Obrázek 12. Metoda dělení oblastí [upraveno podle 26] .....	30
Obrázek 13. Metoda shlukové analýzy [33] .....	31
Obrázek 14. K-Means metoda: Vstup $\mapsto$ Začátek vektoru $\mu_j \mapsto$ Klasifikace $\mapsto$ Přepočítání vektoru $\mu_j \mapsto$ Klasifikace [33] .....	32
Obrázek 15. OCT B-sken: manuální segmentace na základě regionů. Červeně je vrstva RNFL, zeleně vrstvy sítnice, tmavě modře pigmentový epitel a světle modře cévnatka [36] .....	33
Obrázek 16. Výsledek předzpracování: a) původní obrázek, b) jasový kanál L, c) operace morfologie, d) konvoluční ošetření Gaussova jádra [37] .....	35
Obrázek 17. Konvoluční zpracování obrázku [37] .....	35
Obrázek 18. Regiony OD a OC [37] .....	36
Obrázek 19. Experimentální výsledky navrhované metody: a) původní obraz, b) předzpracovaný obraz, c) referenční oblast, d) Gaussova funkce jádra, e) počáteční obrysy biregionální evoluce kontur, f) a g) biregionální evoluce kontur, h) konečná segmentace [37] .....	37
Obrázek 20. a) snímek optického nervu, b) zelený kanál, c) červený kanál, d) strukturované okraje, e) hrany získané aplikací Prewittovým operátorem na zelený kanál, f) hrany získané aplikací Prewittovým operátorem na červený kanál [35] .....	39
Obrázek 21. Proces oříznutí dílčího snímku OD [35] .....	39
Obrázek 22. P - políčka s vnějšími okraji objektů, L - odpovídající segmentační masky [35] .....	40
Obrázek 23. Různé výsledky pro nastavení hodnot f: a) f=1, b) f=0,618, c) f=0,4 [35] .....	41
Obrázek 24. a) Kruhová aproximace hranice vnějšího průměru, b) efekt překrytí kruhu na snímku očního pozadí [35] .....	41
Obrázek 25. Ukázka snímků z databáze Drive .....	42
Obrázek 26. Ukázka snímků z databáze Stare .....	42
Obrázek 27. Ukázka snímků z databáze Clarity RetCam3 .....	43
Obrázek 28. Ukázka snímků z databáze Envision RetCam3 .....	43
Obrázek 29. Ukázka snímků z databáze Phoenix ICON .....	43
Obrázek 30. Blokové schéma návrhu algoritmu pro detekci a extrakci optického disku .....	45
Obrázek 31. a) obdélníkový, b) elipsoidní, c) nepravidelný mnohoúhelník, d) volně definovatelný ....	46
Obrázek 32. Ukázka manuální anotace s originálem překrytým s binární maskou a binární maska ....	47
Obrázek 33. Blokové schéma předzpracování obrazu .....	48
Obrázek 34. Výběr chromizačních složek z databáze Envision RetCam3 .....	49

Obrázek 35. Převedení nativního snímku z databáze Stare do stupňů šedi .....	50
Obrázek 36. Histogram jasu $L=256$ jasových úrovní [25] .....	51
Obrázek 37. Histogram u šedotonového snímku z databáze Drive .....	52
Obrázek 38. Ukázka CLAHE u databáze Drive .....	52
Obrázek 39. Globální, lokální a bodová transformace [41].....	53
Obrázek 40. Jasová transformace Phoenix ICON: a) nativní snímek, b) snímek po převedení do stupňů šedi, c) jasová transformace.....	53
Obrázek 41. Bilaterální filtrace u databáze Clarity RetCam3 .....	55
Obrázek 42. Inicializace a s iteračním krokem 50, 100, 150 a 200.....	59
Obrázek 43. Ukázka binarizace pro databázi Clarity RetCam3.....	59
Obrázek 44. Ukázka binarizace u databáze Drive.....	60
Obrázek 45. Ukázka binarizace pro databázi Envision RetCam3.....	60
Obrázek 46. Ukázka binarizace pro databázi Phoenix ICON .....	60
Obrázek 47. Ukázka binarizace pro databázi Stare .....	61
Obrázek 48. Fúze u databáze Clarity RetCam3.....	62
Obrázek 49. Fúze u databáze Drive .....	62
Obrázek 50. Fúze u databáze Envision RetCam3.....	62
Obrázek 51. Fúze u databáze Phoenix ICON .....	63
Obrázek 52. Fúze u databáze Stare .....	63
Obrázek 53. Graf porovnaných průměrných hodnot u výsledků korelačního koeficientu pro binární masky.....	66
Obrázek 54. Graf porovnaných průměrných výsledků korelačního koeficientu pro intenzity OD .....	67
Obrázek 55. Graf porovnaných průměrných hodnot u výsledků indexu strukturální podobnosti pro binární masky .....	67
Obrázek 56. Graf porovnaných průměrných hodnot u výsledků indexu strukturální podobnosti pro intenzity OD.....	68
Obrázek 57. Graf porovnaných průměrných hodnot u výsledků Střední kvadratické chyby pro binární masky.....	68
Obrázek 58. Graf porovnaných průměrných hodnot u výsledků střední kvadratické chyby pro intenzity OD.....	69
Obrázek 59. Graf porovnaných průměrných hodnot u výsledků přesnosti .....	69
Obrázek 60. Graf porovnaných průměrných hodnot u výsledků senzitivity .....	70
Obrázek 61. Graf porovnaných průměrných hodnot u výsledků F-míry.....	70
Obrázek 62. Graf porovnaných průměrných hodnot u výsledků preciznosti.....	71
Obrázek 63. Graf porovnaných průměrných hodnot u výsledků koeficientu Dice .....	71
Obrázek 64. Graf porovnaných průměrných hodnot u výsledků koeficientu podobnosti Jaccard.....	72
Obrázek 65. Graf porovnaných průměrných hodnot u výsledků specificity .....	72
Obrázek 66. Návrh softwarového prostředí.....	73
Obrázek 67. Načtení obrázku .....	74
Obrázek 68. Manuální označení .....	74
Obrázek 69. Binární maska - výsledek manuálního označení .....	75
Obrázek 70. Zvolení velikostí parametrů.....	75
Obrázek 71. Výsledný překrytý obraz s evaluačními parametry .....	76

## Seznam tabulek

Tabulka 1: Technické parametry snímků.....	44
Tabulka 2. Průměrné hodnoty evaluačních parametrů .....	65
Tabulka 3. Průměrné hodnoty evaluačních parametrů .....	66

# Úvod

Oční vyšetření je považováno za jedno z nejdůležitějších vyšetření. V této době pomáhá oftalmologům v diagnostice řada optických přístrojů. Přístroje nejen že dokážou nasnímat oči, ale také dokážou na základě algoritmů u průměrných zdravých očí zaznamenat a detekovat oční onemocnění, které by běžným pohledem nebylo prokazatelné.

Při zpracování diplomové práce bylo použito několik datasetů. První datasety byly volně stáhnutelné snímky sítnice dospělých lidí s fyziologickými nálezy nebo s různým sítnicovým onemocněním. Druhá sada datasetů byly snímky sítnice, které poskytlo Oční centrum Fakultní nemocnice Ostrava. Jednalo se o snímky sítnice nedonošených dětí, tedy se sítnicovým onemocněním Retinopatie nedonošených.

Teoretická část se věnuje popisu optických přístrojů. V této části byl představen princip a funkčnost přístrojů, které slouží pro vyšetřování oka, tedy konkrétně zadní části oka, a to sítnice. Každá z metod snímání sítnice funguje na jiném principu. Výsledný získaný obraz je pro každý přístroj rozdílný. Nedílnou součástí teoretické části je i popis procesu segmentace. Segmentace je metoda, která se využívá pro zpracování digitálního obrazu. Cílem segmentace je rozdělit obraz na dílčí segmenty. Tyto segmenty jsou dále použity ke zpracování s tím, že dojde k analýze každého dílčího segmentu. Při běžném zpracování obrazu se využívá algoritmů, které se snaží vymezit pouze konkrétní oblast zájmu v obraze. Výstupem segmentace je maska, která určuje klasifikační třídu pro každý pixel. Metoda segmentace je tvořena několika technikami.

Cílem této diplomové práce bylo vytvoření algoritmu pro extrakci a detekci optických disků. Význam spočíval ve zpracování snímků z různých datasetů, které byly dále analyzovány. Čím kvalitněji a přesněji se dokázal najít a označit optický disk, tím hodnotnější informace o zpracování se dostalo. Nejprve se ve snímku manuálně vymezila oblast zájmu, tedy optický disk. Výstupem byl zlatý standard. Poté byl stejný snímek důkladně předzpracován a pomocí metody aktivních kontur bez hran, která využívá deformovatelných křivek, byl vytvořen algoritmus segmentace. Výstupem byl binární obraz, kde optický disk měl hodnotu logická 1, pozadí mělo hodnotu logická 0. Kvalita výsledné segmentace se vyhodnocovala tak, že bylo potřeba mít subjektivní výstup manuální anotace, tj. zlatý standard a vůči tomu se musela přeměřit kvalita automatického segmentačního algoritmu u optických disků. Vyhodnocení se provedlo na základě evaluačních parametrů.

Závěrem práce bylo vytvoření grafického uživatelského rozhraní (GUI). V této fázi GUI byl načten snímek a zvoleny odpovídající parametry. Po inicializaci optického snímku došlo k jeho ohraničení a vytvoření segmentace. GUI mělo hlavní záměr v tom, že sjednotilo jednotlivé metody pro detekci optického disku a zjednoduší tak uživatelům práci se zpracováním snímků optického disku.

# 1. Zobrazovací metody pro diagnostiku očního pozadí

Zobrazovací metody jsou metody, která nám mají pomoci zobrazit jednotlivé části lidského těla. Jedná se tak i o zobrazování částí, které jsou skryté lidskému oku, tedy části nacházející se uvnitř těla. Mnohé tyto zobrazovací metody jsou takové, které nenaruší ani nezatíží vyšetřovanou tkáň. Výsledky takových zobrazení je nutné dále zpracovat a uchovat pro možnost dalšího a podrobnějšího zkoumání. Signál z tohoto zkoumání je poté nutné převést do podoby obrazu. Toho lze dosáhnout vzájemným působením fyzikálního signálu s látkovým prostředím vyšetřované tkáně. [1]

V první řadě dochází k detekci samotného signálu. Signál je zpracován pomocí detektorů, které jej převedou do obrazové podoby. V tomto případě mají signály povahu měničů, které jsou schopné zpracovávat jen určitý signál. Zaznamenaný signál je měničem přenesen do elektrické formy a počítačově upraven. Závěrem jsou tyto informace o obraze dále interpretovány hodnotitelem. V tomto případě už záleží jen na kvalitě zobrazeného snímku a na zkušenostech hodnotitele, aby správně výsledek zanalyzoval a stanovil tak diagnózu. [1]

V posledních letech nové lékařské zobrazovací technologie výrazně zlepšily nejen v diagnostice a klinické léčbě různých onemocnění, ale také poskytly nové možnosti pro pochopení patogeneze různých chorob a pro rozvoj nových terapií a zákroků. Vzájemná součinnost oborů k vývoji přispívá. Jedná se například o kooperaci fyziky, medicíny a informatiky. Mnohé zobrazovací technologie, jako je magnetická rezonance, rentgenová počítačová tomografie, ultrazvuk ad. jsou omezené, kvůli malému prostorovému rozlišení. Malé detaily bývají často pozorovány v rozmezí půl milimetru, přitom některé detaily je potřeba rozlišit v řádech mikrometrů a zobrazovacím technikám se nedaří proniknout hluboko do biologických tkání. [2] [3]

U zobrazovacích metod pro diagnostiku očního pozadí se vyšetřuje sítnice oka. Je to jediná část centrální nervové soustavy, která je viditelná zvenčí. Toho lze dosáhnout při vyšetřování očí využíváním přímé a nepřímé oftalmoskopie. V současné době je možné zakoupit široké spektrum oftalmologických přístrojů, které slouží pro diagnostiku. [4] [5]

U přímé oftalmoskopie se jedná o ruční nástroj, jehož součástí je zabudované osvětlení a zabudovaná dioptrická sklíčka. Vyšetřující je v těsné blízkosti vyšetřovaného a nepotřebujeme k tomu další přidané komponenty. Vyšetření přístrojem je závislé na velikosti zornice vyšetřovaného. Čím více je zornice rozšířená, tím lze lépe vidět oční pozadí tvořené sítnicí a cévnatkou. Dále bude oční pozadí označováno jako fundus. [6]

Nepřímá oftalmoskopie je naopak metoda, která k zobrazení očního pozadí využívá dalších komponentů. Patří zde např. šterbinová lampa společně s fundoskopickou čočkou (Volkova, Hrubyho) a fundus kamera. Pozorovaný obraz očního pozadí je převrácený. Výhodou nepřímé oftalmoskopie je možnost vidět i do periferie fundu. [6] [7]

## 1.1 Oftalmoskop

Oftalmoskop je nástroj přímé oftalmoskopie. Oftalmoskop obsahuje intenzivní zdroj světla, optiku s předsádkami čoček, které korigují refrakční vadu vyšetřovaného a vyšetřujícího. Filtry

s rozdílnou vlnovou délkou a intenzitou světla. Za využití velké intenzity světla, které prochází optickou soustavou, je zvětšen obraz zobrazované sítnice. [8]

Obraz, který pozorujeme oftalmoskopem, je přímý a je několikanásobně zvětšený. Obvykle má 2 nebo 3 velikosti světelného zdroje, které se používají v závislosti na úrovni rozšíření zornice. Malé světlo se používá, když je zornice velmi zúžená. Toto nastává, pokud je v místnosti dostatečné osvětlení a není využito žádných medikamentů pro rozšíření zornic. Velké světlo je nejlepší, pokud se k rozšíření zornic používají oční kapky. Při nerozšířené zornici se nejčastěji využívá střední světlo. Další možností, kterou můžeme u oftalmoskopu zvolit je půlkruhové světlo. Toho se využívá, pokud je transparence oční čočky málo propustná, tedy je-li na ni šedý zákal. Půlkruhové světlo prochází pouze přes průhlednou část zornice. Je to z toho důvodu, aby nedocházelo k zpětnému odrazu světla. Označení RF znamená Red free light a jde o světlo bez červené složky světelného spektra tzn. že při nastavení bude sítnice vypadat černobíle. Tím se zvýší kontrast. Štěrbínový paprsek, který vypadá jako úzký proužek se využívá k vyšetření neobvyklých změn na rohovce, čočce nebo sítnici. Světlo modré barvy lze použít k pozorování odřenin a vředů rohovky po obarvení fluoresceinem. Mřížka se používá k hrubé aproximaci relativní vzdálenosti mezi lézemi sítnice. Kolečko pak samostatně slouží k zaostřování. Může mít i filtry pro denní světlo nebo také polarizační. Hlavní části, které tvoří oftalmoskop, jsou zdroj světla, clona, dvě čočky a malé zrcátko s náklonem 45°. [5] [7] [9]

### 1.1.1 Princip oftalmoskopu

Využívá se malého nakloněného zrcátka, které je umístěno těsně pod pozorovacím otvorem. Pomocí dvou ovládacích koleček se nastavuje intenzita světla, průměr nebo i barva paprsku. Osvětlovací systém vyšle světlo ze zdroje. Světelné paprsky ze zdroje se mírně sbíhají pomocí první čočky. Druhá čočka pak obraz zaostří a vytvoří jej na zrcadle. Světelné paprsky se na zrcadle rozcházejí a vytvářejí kuželovitý svazek paprsků. Paprsek vstupuje do oka vyšetřovaného, kde projde očními médii až na sítnici oka. Světlo se odráží od sítnice do různých směrů, ale pouze některé z odražených paprsků projdou ven až do zrcátka, kde mohou být některé z paprsků ztraceny pro pohled vyšetřujícího a některé projdou vyšetřovacím otvorem. [9]



Obrázek 1. Oftalmoskop [vlastní]

## 1.2 Štěrbínová lampa

Štěrbínová lampa je v oftalmologii nepostradatelnou součástí vybavení oftalmologa. Používá se nejen k vyšetřování předního segmentu, ale pomocí čoček, ať už kontaktních tzn. dotýkají se oka, či bezkontaktních čoček, lze vyšetřit zadní segment. Štěrbínová lampa tvoří binokulární mikroskop a osvětlovací jednotky. Podle toho, kde je situován světelný zdroj, se štěrbínové lampy dělí na 2 typy. Podle výrobce Haag Streit jsou to lampy se zdrojem světla nahoře. Podle výrobce Zeiss jsou to lampy se zdrojem světla dole. Štěrbínová lampa se zdrojem světla nahoře využívá zrcadlo, které odrazí paprsky světla jdoucí ze zdroje dále do oka. Štěrbínová lampa se zdrojem světla dole taktéž vyše paprsky světla ze zdroje do oka vyšetřovaného. Tentokrát jej ale vyše pomocí prizmatu (hranolu), na kterém dochází k ohybu dopadeného světla. [4] [10]

Pro zaznamenání obrazu jsou mnohdy na štěrbínové lampy instalovány fotoaparáty i videokamery. Tak může být zachycován obraz statický = v klidu, ale i dynamický = v pohybu. Pro zobrazení se používají CCD čipy, které jsou schopné dosáhnout rozlišení větší jak 10Mpix. Pokud se jedná o záznam videa, může dosáhnout FullHD s rychlostí snímání 15-30 fps. Dělič paprsků, který se nachází mezi objektivem a měničem zvětšení, porovnáva světelný tok odkloněný do videoadaptéru a světelný tok, který postupuje do okuláru. Obraz sítnice lze vyfotit při vyšetření na štěrbínové lampě. Musí se ale použít např. Volkova čočka o optické mohutnosti 78 dioptrií nebo 90 dioptrií. Pro náročnost takového snímku se proto raději, než štěrbínové lampy používají fundus kamery. Konstrukce štěrbínové lampy je tvořená třemi částmi. Je to zvětšovací systém – binokulární mikroskop se zvětšením 5-40 krát, osvětlovací systém, který má halogenové a xenonové zdroje a zároveň obsahuje filtry a to modrý kobaltový, zelený, žlutý, difúzní, polarizátor. Poslední je mechanický systém, který zajišťuje posuvy přístroje. [4]



Obrázek 2. a) Štěrbínová lampa Haag Streit, b) Štěrbínová lampa typu Zeiss [vlastní]

### 1.2.1 Princip šterbinové lampy

Šterbinová lampa se skládá ze 3 hlavních částí: osvětlovací systém, stereomikroskop neboli zvětšovací systém, a mechanický systém. Osvětlovací systém je tvořený mikroskopickým paprskem světla. Paprsek má maximální intenzitu, kterou lze měnit. Stejně tak lze měnit i jeho délku, šířku a polohu. Dnešní přístroje vychází z Köhlerového principu osvětlení. Dle tohoto principu je světelný zdroj přenášený do objektivu přes kolektor a šterbinovou clonu. Zdroj světla může pocházet z nízkonapěťové žárovky, halogenové žárovky nebo i LED diod. Mikroskop se snaží zajistit ideální pozorování prostoru, tedy velikost a zorné pole, aby bylo možno manipulace s okem. [10]

### 1.3 Fundus kamera

Design fundus kamery je založen na monokulární nepřímé oftalmoskopii. Z větší části se využívá pro zobrazování zadní části oka. Fundus kamera může taky využívat pro zaznamenání přední části oka. Díky různým filtrům lze světlo přizpůsobovat tak, aby fotografie byla co nejkvalitnější a zobrazila nám strukturu oka. Světlo vstupující do oka se odrazí od sítnice a vrátí se zpátky do objektivu. CCD čipy pak převedou obraz do digitální úpravy. Zachycený snímek může mít rozlišení 18 Mpix, kdy snímání fundu má více, jak 100 stupňů. [4] [11]

Jak už bylo řečeno, fotografie fundu dokumentuje sítnici, tedy neurosenzorickou tkáň v našich očích, která převádí optické obrazy na elektrické impulsy. Sítnici lze fotografovat přímo, díky zornici, která slouží jako vstup i výstup pro osvětlovací a zobrazovací světelné paprsky. Vyšetřovaný sedí u fundus kamery s opřenou bradou i čelem v opěrce. Vyšetřující zarovná a zaostřuje obraz. Když je obraz zaostřený, dojde buď automaticky nebo pomocí vyšetřujícího k vyvolání blesku. Tímto vznikne snímek očního pozadí. Fotografie, která se vytvoří, pak slouží oftalmologům k diagnostice, identifikaci změn a ke sledování očních onemocnění. [12]

Snímky očního pozadí jsou nedílnou součástí očního vyšetření. Lze sledovat progresi glaukomu (zelený zákal), při němž dochází k postupnému poškození zrakového nervu. Taktéž lze sledovat progresi diabetické retinopatie, Jedná se o poškození sítnice cukrovkou. Lze sledovat poškození sítnice onemocněním VPMĐ – Věkem podmíněná makulární degenerace. [12]



Obrázek 3. Fundus kamera [4]




### 1.3.1 Konstrukce fundus kamery

Konstrukce je tvořena objektivem, kondenzačními čočkami, děliči paprsků, zrcadel, masek, difuzérů a polarizátorů, které společně směřují světlo skrz zornici oka a shlukují světlo odražené od povrchu sítnice. Následně ho přenášejí do zobrazovací optika, které vytvoří obraz sítnice na obrazovce detektoru. Modernější verze těchto systémů jsou vybaveny dalšími funkcemi, jako je automatická analýza a algoritmy. Důležitou součástí jsou také filtry, které lze uplatnit na kamerové systémy při autofluorescenci, fluoresceinové angiografii a indocyaninové zeleni. [11]

### 1.3.2 Princip fundus kamery

Zdrojem světla je buď lampa nebo elektronickým bleskem. Světlo je promítáno přes sadu filtrů na kulaté zrcadlo. Zrcadlo odráží světlo nahoru do řady čoček, které zaostřují světlo. Masky na nejvyšší čočce připomíná tvar koblíhy. Světlo ve tvaru koblíhy se odráží na kulaté zrcadlo s centrálním otvorem, vychází z fotoaparátu přes čočku objektivu a přes rohovku postupuje dále do oka. Pokud je osvětlovací systém a obraz správně zarovnan a zaostřen, výsledný retinální obraz vychází z rohovky přes centrální neosvětlenou část koblíhy. Světlo pokračuje centrálním otvorem dříve popsaného zrcadla přes zařízení pro astigmatickou korekci a dioptrické kompenzační čočky zpět do systému jednookých zrcadlovek. [12]

Blízká infračervená světelná dioda (LED) zajišťuje osvětlení během zaměřování oka pacienta a bílá LED se používá pro snímání obrazu. To umožňuje menší konstrukci stroje, delší životnost a menší emise tepla ve srovnání s typickou xenonovou výbojkou. LED diody udržují světelné charakteristiky, jako je teplota barvy, světelný tok a distribuce světla, což umožňuje řízenou a reprodukovatelnou osvětlovací jednotku. Zornice je manuálně zarovnaná pomocí techniky děleného obrazu ve směru každého z cílů tak, aby byly získány obrazy různých oblastí sítnice. Pro prohlížení obrázků se používá počítačového rozhraní. [11]



Obrázek 4. Snímek sítnice zachycený fundus kamerou [vlastní]

## 1.4 Optická koherenční tomografie (OCT)

Optická koherenční tomografie je zobrazovací technika, která umožňuje trojrozměrné zobrazování průřezů v biologických tkáních s prostorovým rozlišením 1-15  $\mu\text{m}$  i méně. Rozlišení v řádech mikrometrů je dáno díky různým světelným zdrojům. Jedná se o luminiscenční diody, ultrakrátké pulzní lasery nebo superkontinuální lasery. Na základě zobrazené tkáně jsme schopni vyhodnocovat výsledky. V našem případě se jedná o zobrazovací metodu určenou pro zobrazení struktur oka. Technika vytváří příčné řezy struktury tkáně. OCT umožňuje vysoké prostorové rozlišení, zobrazování mikrostruktury tkáně s vysokým rozlišením a v reálném čase a také přesné polohové zobrazení tkáně. [3] [6] [13]

Měření je dosaženo časovým zpožděním echa a velikostí zpětně rozptýleného světla. Proto lze říci, že je to technika velice podobná ultrazvuku. Rozdíl oproti ultrazvuku je v tom, že OCT dosahuje jemnějšího rozlišení. Dle funkčnosti zobrazování, je základním principem OCT využívání světelných paprsků, tedy interference světla (IR). To je také důvodem, proč pomocí OCT máme lepší rozlišení než při ultrazvuku. [3] [6] [13]

OCT je zcela bezkontaktní a díky tomu i nezatěžující pro organismus nebo jednotlivé tkáně oka. OCT se uplatňuje pro zobrazení míst na sítnici. Konkrétně se jedná o zobrazení makuly. Jako makula je označována žlutá skvrna z latinského macula lutea. Jedná se o místo na sítnici, které zajišťuje nejostřejší vidění. V centru makuly leží jamka označována, jako fovea, z latinského fovea centralis maculae. Druhou zobrazovanou částí sítnice bývá papila. Papilou (Discus nervi optici nebo papilla nervi optici) je myšlena slepá skvrna, nebo taktéž terč zrakového nervu. Jedná se o místo, kde vzniká zrakový nerv a ten je vedený dále do mozku. [6] [7] [14]

Aby snímání oka bylo co nejpřesnější, musí být obraz co nejpřesněji centrováný. Také by měla být optimální průchodnost očními médii. Například u šedého zákalu může být transparence oční čočky značně zhoršena a sken by nemusel v plné míře ukázat vyšetřované místo. Stejně tak pro skenování může být kontraindikací pohyby očí a hlavy. V tomto případě se jedná o případy, u kterých není možná schopnost spolupráce nebo není schopnost sledování fixační značky. [15]

OCT se běžně používá v ambulantních zařízeních oftalmologů a je důležitým diagnostickým prostředkem pro zjišťování očních onemocnění. Díky OCT vyšetření lze rozpoznat onemocnění makuly, diabetickou retinopatii, glaukom (zelený zákal) a mnoho dalších onemocnění. Včasným a rychlým OCT snímáním lze onemocnění zachytit včas a pokud je možnost, zvolit tak adekvátní léčbu. [13] [16]

### 1.4.1 Konstrukce OCT

Konstrukce OCT je tvořena štěrbinovou lampou s optickou mohutností 78 dioptrií, zdrojem infračerveného záření – pulsním laserem nebo superluminiscenční diodou (SLD), videokamerou, Michelsonovým interferometrem, detektory světla a monitory (černobílý obraz snímané části oka). Dochází k vytváření optického řezu snímané sítnice a počítačem je vytvořen barevný obraz. OCT využívá optickou odrazivost jednotlivých tkání a je zobrazovaná v barvách, které neodpovídají reálné barvě struktury. [6]



Obrázek 5. OCT s počítačovou jednotkou [vlastní]

#### 1.4.2 Princip OCT

Světlo, které prochází okem, projde čtyřmi optickými prostředími, z nichž každé z prostředí se vyznačuje jinými atributy a lomivostí. Jedná se o rohovku, komorovou vodu, čočku a sklivce. Po průchodu paprsku těmito segmenty dopadne světlo na sítnici oka. Jak hluboko je světlo schopno dopadnout na sítnici, je ovlivněno jeho vlnovou délkou. Světlo o vyšších vlnových délkách proniká hlouběji a naopak. [14]

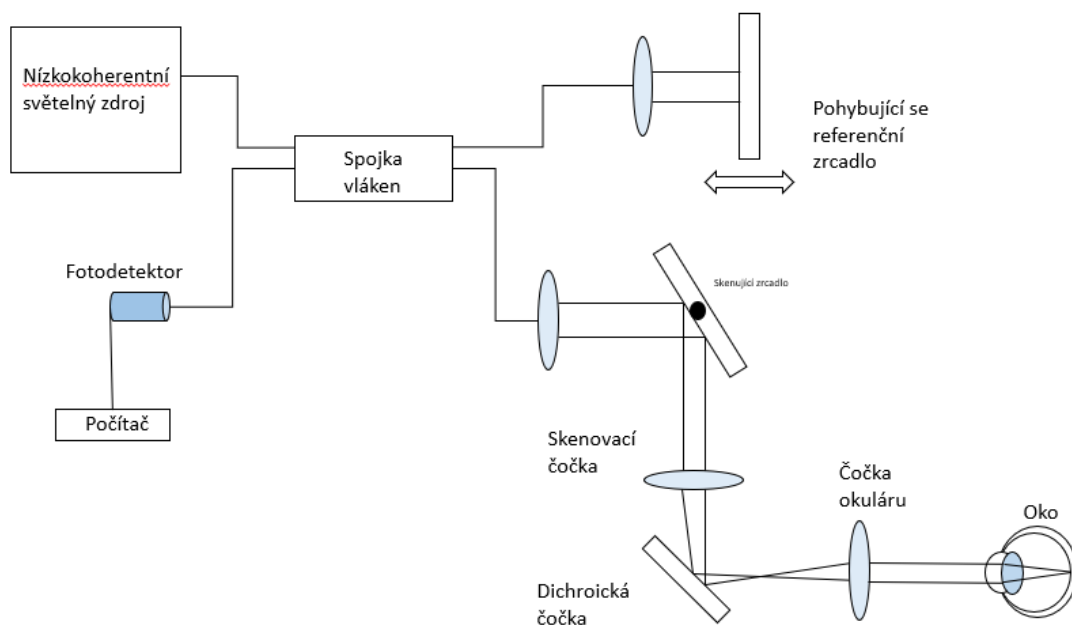
Zdrojem světla je superluminiscenční dioda. Superluminiscenční dioda vyzáří světlo na polopropustné zrcadlo. Na zrcadle dojde k rozdělení vyslaného paprsku. Paprsky směřují podél dvou různých ramen interferometru. První paprsek je takzvaně vzorový nebo často bývá označený, jako referenční. Jedná se o paprsek, u kterého známe jeho vlnovou délku a tím i víme do jaké vzdálenosti neboli hloubky se dostane. V referenčním rameni je světlo zpětně odraženo referenčním zrcadlem a vrací se do interferenčního systému, přičemž se šíří stejnou cestou, kterou přišlo, ale v opačném směru. Druhý paprsek projde vrstvami sítnice a poté je odražen zpět a zaznamenán detektorem. Zpětně odražené paprsky se spojují a vytvářejí interferenční obrazec, který jej detekuje a analyzuje. Odlišnosti mezi jednotlivými paprsky způsobí fázový posun. Michelsonův interferometr pak vyhodnocuje diferencii svazků paprsků. Výsledky jsou pak digitálně upraveny. Skenování probíhá ve dvou zobrazovacích módech a to A-scan a B-scan. A-scan tvoří axiální odrazivost od různých vrstev objektů. B-scan tvoří průřez strukturou. [1] [3] [6] [13] [17]

Odražené paprsky jsou vyhodnocovány barevně nebo černobíle a zaznamenávají se ve formě dvourozměrného obrazu (2D) a nebo třírozměrného obrazu (3D). Barevné zobrazení obrazu je v jistém

ohledu jednodušší pro výsledné vyhodnocování. Červené až bílé barvy zaznamenávají tkáně s vysokou odrazivostí. Modře až černě jsou zaznamenány tkáně s nízkou odrazivostí. Žlutozelenou barvu pak mají rozhraní. Rychlost skenování sítnice je přibližně 1 sekunda. Za tak krátkou dobu lze získat až 500 000 naskenovaných bodů. [6]

#### 1.4.2.1 TD OCT (Time domain OCT)

TD OCT neboli Optická koherentní tomografie v časové doméně využívá interferometrii o nízké koherenci světelného zdroje a skenovací referenční zpoždění. Jak už bylo prezentováno v principu, OCT vytváří průřezové snímky za využití rozdílu mezi odraženým světlem z biologické tkáně a referenčním světelným paprskem. Dopadající světlo na tkáň může být rozptýleno, přeneseno nebo pohlceno. Podle principů interference se světlo ze světelného zdroje rozdělí na dvě části. V optickém děliči se světlo rozdělí na dva paprsky. První referenční paprsek se odrazí od referenčního zrcadla, které je v translačním pohybu, což umožňuje referenčnímu světlu urazit známou délku dráhy a podstoupit měřitelné proměnné časové zpoždění. Druhý paprsek prochází zobrazovanou tkání. Uvnitř zobrazované tkáně se paprsek odrazí. Od každé vrstvy tkáně, kterou projde, se zobrazí v různých osových vzdálenostech. Oba paprsky probíhají současně. Při návratu zpět se oba paprsky opět spojí v optickém děliči paprsků a jsou odeslány do optického detektoru. Pokud se délky optických drah paprsků shodují, dochází k jejich interferenci. Protože dochází ke skenování každého bodu z referenčního zrcadla ve směru hloubky paprsku, který prošel vyšetřovanou tkání a tato intenzita světla je zaznamenána ve fotodetektoru, říkáme, že je výstupem A – scan. Pokud bychom chtěli vytvořit B – scan, musel by být snímán laterálně. U TD OCT dojde ke 400 skenům za sekundu. [3] [13] [15] [16]

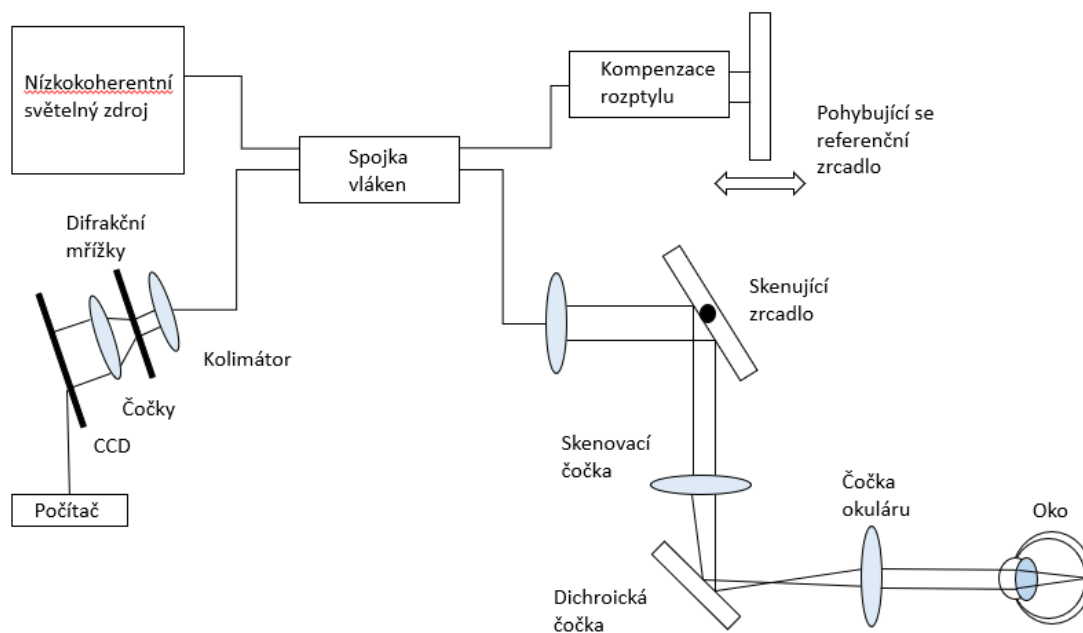


Obrázek 6. Princip TD OCT [upraveno podle 16]

### 1.4.2.2 SD OCT (Spectral domain OCT)

Jedná se o typ FD OCT. FD OCT je Fourier domain nebo také označován jako frekvenční doména. Využívá efektivněji nízkokoherentní interferometrie. Zatímco při měření TD-OCT jsou světelné echa detekovány postupně krokovým pohybem referenčního zrcadla, u FD-OCT je zrcadlo statické. Světelná echa přicházejí současně ze všech axiálních hloubek a jsou detekovány a zachyceny současně. Oproti TD OCT jsou data získávána vyšší rychlostí a jsou schopna vytvářet A – scany bez potřeby mechanického skenování délky optické dráhy. U metody dochází k registraci interferenčního spektra, ze kterého se vypočítává A – scan pomocí Fourierovy transformace. FD OCT na spektrometru je označován, jako SD OCT neboli OCT spektrální domény.

U tohoto typu snímání dochází k rozložení na frekvenční spektrum. SD OCT je podobný TD OCT, ale bodový detektor je nahrazen spektrometrem. Paprsek dopadne na difrakční mřížku, kde dojde k jeho rozložení na frekvenční spektrum, a je dále zaznamenáno spektrometrem. Spektrometr tedy prostorově odděluje výsledky různých vlnových délek a vytváří z něj řádkový obraz, který je zaznamenáván vysokorychlostní CCD řádkovou skenovací kamerou. Každý údaj z kamery tvoří spektrální interferogram se superpozicí proužkových vzorů. Výsledky jednotlivých skenů jsou přepočítávány pomocí Fourierovy transformace. Metoda je rychlejší než TD OCT, je schopna udělat až 50 000 skenů za sekundu. [3] [13] [15] [16]



Obrázek 7. Princip SD OCT [upraveno podle 16]

### 1.4.3 Topografická mapa

Pro zobrazení zadního segmentu má normální sítnice konkávní povrch vzhledem k dopadajícímu světlu. Při topografii zadního oka je však možné, že patologie může způsobit zploštění povrchu sítnice nebo změnu příznaků, tedy dojde k přechodu z normálního konkávního povrchu na povrch konvexní. Výsledky OCT jsou zaznamenávány barevnou mapou, která ukazuje změny velikosti i směru zakřivení. Normální poloměry zakřivení sítnice jsou označovány zelenou barvou. Žlutá barva označuje strmější,

konkávnější zakřivení. Fialová barva označuje plošší oblasti. Růžová a červená označuje konvexní povrchy tzn. Zadní část je tlačena směrem ke sklivci. [6] [18]

Topografická mapa se může v závislosti na typu přístroje lišit. Při vyšetření makuly se zobrazí kruh o průměrech 1, 3 a 6 mm. Každý kruh je rozdělený na 4 kvadranty. Jsou to S – superior - horní, I – inferior - dolní, N – nasal - vnitřní, T - temporal – vnější. Normální velikost sítnice se může napříč přístroji lišit. Je to dáno kvůli rozdílné definici vrstvy sítnice využívané v OCT a segmentačními algoritmy. [6] [13]


Pro diagnostiku glaukomu se používají topografické mapy udávající tloušťku vrstvy nervových vláken sítnice (RNFL), které jsou odvozeny z kombinace kruhových a radiálních skenů OCT na optickém disku. Analýza RNFL poskytuje alternativu k vizuální kontrole neuroretinálního okraje optického nervu a také kvantitativnímu odhadu axonální ztráty gangliových buněk sítnice. Sektorová a globální tloušťka RNFL vyžaduje přesné měření bod od bodu. Porovnává a posuzuje progresi vzhledem k hodnotám referenčních údajů. Proto je nezbytné minimalizovat nežádoucí vlivy, jako jsou náklony hlavy, otáčení očí pro každý jednotlivý sken. Stejně tak musí být zohledněna anatomie, která se u jednotlivých osob může lišit. [13] [19]

Většina platform OCT poskytuje hodnoty tloušťky RNFL v pevné vzdálenosti od zřetelného nervu. To je přibližně o průměru 3,5 mm. Je kruhový a tloušťka příčného řezu je ve středu optického nervu. Jak lze očekávat z dobře známého vzoru glaukomatózního ztenčení neuroretinálního okraje zřetelného nervu, spodní kvadrant RNFL obecně podléhá největšímu ztenčení a má největší plochu pod křivkou operačních charakteristik přijímače. Ve skutečnosti se tloušťka RNFL značí v kvadrantu tj. dolní, horní, nazální, temporální. [19]

Skenovací vzorce slouží pro zobrazení optického disku a proto jsou nápomocné pro diagnostikování glaukomu. U různých typů OCT zařízení může být při skenování optického disku použit odlišný software:

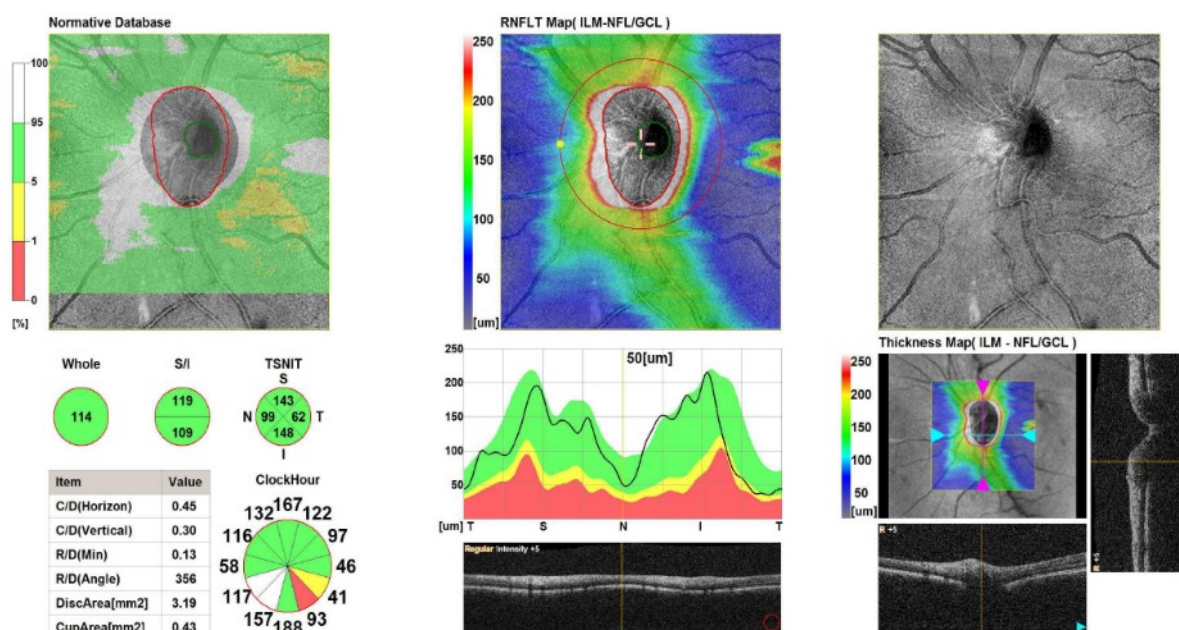
- 1) RNFL Thickness: je soustředěný na střed papily. Má tři cirkulární skeny, jejichž průměry jsou 3,4 mm. Dochází k A – skenům, které mají za úkol vyhodnotit sílu vrstvy nervových vláken. Výsledky RNFL jsou znázorněny pomocí 12 rozdělených segmentů. Výsledky jsou porovnány s optimálními hodnotami a barevně se odlišují, pokud dojde k odchylce od standardu. Zároveň se znázorňuje křivka, která určuje výšku RNFL
- 2) RNFL Map: je soustředěný na peri papilární oblast. Má 6 skenů, jejichž poloměry jsou 1.44, 1.69, 1.90, 2.25, 2.73 a 3.40 mm. V této části dochází k tvorbě mapy s přesně znázorněnými hodnotami výšky RNFL.
- 3) Optical Disc: Má 6-24 linií, které jsou paprskovitě uspořádány. V této části je přesný rozbor papily zřetelného nervu. Je zde znázorněn poměr C/D neboli Cup/Disk, tedy poměr mezi exkavací a terčem nervu, neuroretinální lem ad. [6]





Obrázek 8. Horizontální řez vrstev sítnice [vlastní]

Vrstvy sítnice jsou následující: CHO – cévnatka, RPE – retinální pigmentový epitel, PRI/PRO – vnitřní a zevní segmenty receptorů, ELM – zevní limitující membrána, ONL – zevní jaderná vrstva, OPL – zevní plexiformní vrstva, INL – vnitřní jaderná vrstva tvořená bipolárními buňkami, IPL – vnitřní plexiformní vrstva, GCL – vrstva gangliových buněk, RNFL – vrstva retinálních nervových vláken, ILM – vnitřní limitující membrána.



Obrázek 9. Vrstva nervových vláken a terč zrkového nervu [vlastní]

Pro porovnání výsledků zobrazovaného zrkového nervu s normou zdravých dat zobrazovaného zrkového nervu u stejného věku i pohlaví je graf RNFL. Zelená – normální hodnoty, žlutá – snížená hraniční hodnota, červená snížená hodnota, bílá - neověřená hodnota.

## 1.5 Heidelberský retinální tomograf (HRT)

„HRT je konfokální laserový skenovací systém umožňující kvantitativní 3D analýzu terče zrakového nervu (TZN) za pomoci topografických (stereometrických) parametrů TZN. V současné době se používá zejména pro diagnostiku a sledování glaukomových změn TZN.“ Tyto změny a progresi glaukomu lze zaznamenávat a zachytit v reálném čase. Pomocí HRT můžeme taktéž zobrazit jak makulu, tak i rohovku. [6] [20]

Je určený k pořizování a analýze trojrozměrných snímků zrakového nervu a parapapilárního RNFL. Konfokální skenovací laser o vlnové délce 670 nm diodový laser vysílá paprsek, který je zaměřen v osách x a y. Jedná se o horizontální a vertikální rozměr zrakového nervu. Také je zaměřen kolmo na osu z, tedy osu podél optického nervu a také na množství odraženého světla z každého snímaného bodu, neboli v každém pixelu. Před detektorem světla se nachází konfokální dírka, která propouští pouze světlo vycházející z příslušné ohniskové roviny do světelného detektoru, zatímco světlo mimo ohniskovou rovinu je maskováno. Odražený obraz z této roviny je zachycen jako dvourozměrný obraz (2D)

Postupně rovnoměrně se vytvářejí optické úseky v intervalech 1/16 mm až 64, v závislosti na C/D optického nervu. Tyto řezy jsou poté spojeny do trojrozměrného obrazu (3D) zrakového nervu. Povrchy optického CUP (exkavace), neuretinálního okraje a peripapilárního prostoru sítnice jsou určeny změnou intenzity odrazivosti podél osy z v každém bodě. Tím se vytvoří topografická mapa pro výpočet poměru exkavace k disku (terče) C/D. První z řad zařízení nazýváno HRT I dokáže snímat na 10, 15 a 20 stupňů šířky. Novější přístroje HRT II a HRT III dokážou snímat pole o 15 stupních s hustotou 384 x 384 pixelů a vylepšenou boční plochu rozlišení o 11 mm. Oba přístroje disponují automatizovanými funkcemi, jako je např. sériové skenování, zprůměrování skenů a jemné zaostření, rozostření a hloubka skenování. Vyšetření lze provádět přes nerozšířené zornice, pořizují se 3 skeny o rozměrech 384 x 384 pixelů a jsou automaticky zarovnány tak, aby vytvořily jeden průměrný topografický snímek, který se použije pro analýzu. [6] [21]

U HRT II a HRT3 jsou získané snímky automaticky analyzovány pomocí speciálních algoritmů, které porovnávají topografické snímky subjektu s normativní databází. HRT II používá různé algoritmy, například různé analýzy lineárních diskriminačních funkcí a Moorfieldsova regresní analýza. [21]

### 1.5.1 Princip HRT

Pro zaznamenání očního pozadí se využívá monochromatické koherentní záření. Laserový paprsek je zaměřen na jeden bod zkoumaného objektu. Světlo odražené od tohoto bodu prochází stejnou cestou zpět přes optiku, je odděleno od dopadajícího laserového paprsku a odkloněno do speciálního detektoru. To umožňuje měřit odražené světlo pouze v jednom bodě objektu. Aby bylo možné vytvořit dvourozměrný obraz, je osvětlující laserový paprsek periodicky vychylován ve dvou rozměrech kolmo k optické ose pomocí skenovacích zrcadel. Proto je objekt snímán bod po bodu postupně ve dvou rozměrech. [6] [22]

V konfokálním optickém systému je před objektivem umístěna malá clona v místě, které je opticky spojeno s ohniskovou rovinou osvětlovací soustavy. Clona má takový účinek, že světlo odražené od předmětu na ohniskové rovině je zaostřeno na díрку, kterou může projít a dojde k jeho detekci. Světlo odražené od vrstev trojrozměrného předmětu nad nebo pod ohniskovou rovinou není zaostřeno do ohniskové roviny a pouze jeho malá část může projít dírkou a je detekována. Proto je



světlo mimo ohnisko silně potlačeno, přičemž potlačení rychle roste se vzdáleností od ohniskové roviny. V důsledku toho má konfokální laserový skenovací systém vysoké optické rozlišení. Rozlišuje detaily nejen kolmo, ale i rovnoběžně s optickou osou, a to znamená, že jde do hloubky. Dvourozměrný obraz získaný v ohniskové rovině proto nese pouze informaci o vrstvě objektu, která se nachází v ohniskové rovině nebo v její blízkosti. Lze jej považovat za optický řez trojrozměrného objektu v ohniskové rovině. [23]

Přístroj dokáže ohraničit terč zrakového nervu a vytvoří topografickou mapu. Mapa je tvořena z šesti výsečí. Jsou to výseče temporální, temporální horní, temporální dolní, nazální, nazální horní a nazální dolní. Jednotlivé výseče se vztahují na celou oblast zrakového nervu. Zjišťuje se poměr C/D, jaká je plocha terče, neuroretinální lem, exkavace a její hloubka, průřezy nervových vláken ad. Všechny hodnoty jsou zpracovány a porovnány s hodnotami optimálního terče zrakového nervu. [20]

## 2. Segmentace obrazu

Segmentací obrazu se rozumí identifikace a oddělení takových oblastí od obrazu, o kterých se předpokládá, že budou odpovídat strukturním jednotkám obrazu. Jedná se tedy o vymezení objektů od pozadí. Je to zvláště důležitá metoda při zpracování biomedicínských obrazů, protože vymezují fyziologické i biologické struktury, o které se zajímáme. Obecné principy segmentace lze rozdělit do několika tříd, které budou dále rozebírány. V biomedicíně je segmentace často velmi náročná, proto se používá více přístupů ke zpracování. Segmentací je myšlená detekce hran a detekce oblastí. [24] [25]

Při popisu segmentace obrazu si musíme nejprve vysvětlit, jak zpracování takového obrazu probíhá. Zpracováním obrazu se rozumí zpracování informace vycházející ze skutečného světa. Tato informace bývá digitálně zpracována počítačem. Pro zpracování obrazu je daná následující posloupnost:

- Snímání a digitalizace obrazu: Analogový obraz je uložen do počítače, následně je vstupní signál digitalizovaný. Vstupní signál je definovaný souřadnicemi funkce  $f(x,y)$  o dvou proměnných, které udávají souřadnice v obraze jsou vstupním signálem. Každý vstupní signál může být vzorkován a kvantován. Tímto způsobem dojde k vytvoření matice. Matice je rozdělena na prvky, z nichž každý bývá nazýván jako obrazový element, také pixel. [26]
- Předzpracování obrazu: Obraz, který chceme vytvořit je omezený nežádoucím působením okolních vlivů. Jedná se o různé druhy rušení, šum, světelné podmínky a další. Proto je předzpracování obrazu chápáno jako nutná činnost, bez které by se zpracování obrazu neobešlo. Je to tedy faktor, který má zamezit vzniku šumu a zkreslení při digitalizaci. Pod úpravou obrazu si můžeme představit jednoduché funkce, jako jsou zmenšení, zvětšení, posunutí či otočení. Funkcí pro úpravu je ale mnohem více. Zde jsou také úpravy jasu a kontrastu, úpravy histogramu, filtrace obrazu a další. Výsledkem předzpracování je histogram, jehož histogram je rozprostřený a bez jakéhokoli rušení. Typickým druhem potlačení nežádoucích faktorů při předzpracování je např. hledání hran. [26] [27]
- Segmentace obrazu: Je to nejsložitější část pro zpracování obrazu. Při segmentaci obrazu musí být ohraničeny oblasti. Tímto krokem je myšleno ohraničení jisté části obrazu, která je v tu chvíli nejpodstatnější a je důležitá, protože je nosičem dat. K příkladům segmentace patří např. prahování, detekce hran, detekce konkrétních bodů a oblastí. Segmentace vyčlení černobílý obraz, tzn. bílé pozadí a černé předměty naší pozornosti nebo obráceně černé pozadí a bílé předměty naší pozornosti.. Tyto předměty se nazývají, jako objekty zájmu, z angličtiny zkratkou ROI (Region of Interest). [26] [27]
- Porozumění obsahu obrazu: Pro porozumění a popis je nezbytné popsat objekty z předchozích charakteristik. Čím kvalitněji je zpracována segmentace obrazu, tím kvalitněji dochází k porozumění. V tomto kroku se vytvoří jistý postup, které předchozí výsledky vymezí do skupin se stejnými znaky. Výsledná tabulka zhodnotí, v jaké skupině se objekty budou nacházet. [26] [27]

Jak už částečně s předchozích popisů vyplynulo, segmentace obrazu je metoda, při které je digitální obraz rozdělen do různých podskupin, které jsou nazvané jako obrazové segmenty. Segmenty pomáhají snížit složitost obrazu a zjednodušit další zpracování nebo analýzu obrazu. Segmentací je myšleno přiřazení k jednotlivým pixelům index segmentu, který vymeze konkrétní objekt v obraze. Všechny obrazové prvky nebo pixely patřící do stejné kategorie mají přiřazený štítek, který je pro ně společný. Namísto zpracování celého obrazu, může být vložen detektor s oblastí vybranou segmentačním algoritmem. Tím se zabrání tomu, aby detektor zpracoval celý obraz, čímž se zkrátí inferenční čas. [28]


## 2.1 Rozdělení segmentace

Segmentačními algoritmy jsou podle přístupu děleny na následující metody

- Metody vycházející z detekce hran – Jsou tvořeny hranovým detektorem s množinou hran v obraze. Detektorů pro detekci hran může být více. Jelikož dochází k odlišným hodnotám okolních pixelů, může být proto každá hrana odhalena detektory.
- Metody orientované na regiony v obraze - Prakticky se jedná o stejné metody, jako metody detekce hran. Každá hrana, která je detekována by měla automaticky vymezit regiony v obraze segmentací s tím rozdílem, že obrysy regionů nemusí vymezovat celý region, ale mohou být neúplné a nedodržené.
- Statistické metody – Jsou tvořeny statistickou analýzou obrazových dat.
- Hybridní metody - Jedná se o metody, které mají z každé metody určitou část a proto je nelze jednoznačně zařadit. Pro segmentaci obrazu je zde používáno matematických popisů. Příklady hybridních metod jsou např. neuronové sítě, morfologické operace, amplitudová projekce ad.
- Znalostní metody - Metody, které používají atlas vzorů nebo modelů segmentových objektů. Objektem je myšlena např. barva, tvar, struktura ad. Pokud tyto objekty známe, je segmentace značně jednodušší. Segmentace algoritmů se snaží objevit a přeměnit známé objekty z atlasů na objekty nalezené v obraze. Proto tento model využívá lineární transformace. [26]

### 2.1.1 Detekce hran

Pro detekci hran lze vycházet ze dvou fází. První fáze hledá hrany, zatímco druhá fáze vytváří segmenty. Následně se snaží nalézt hranice mezi těmito segmenty. Hranami jsou myšleny body (pixely) obrazu, u kterých dochází k rozdílným úrovním jasu. Hrana je charakterizována určitou velikostí i směrem. Hrany tvoří hranici světla a stínu. Každá hrana má náležitý přístup a proto dochází k interpretaci různých výsledků. Výsledkem je myšleno vznik nového obrazu, který je nazýván jako mapa hran. Mapa hran vypočte výslednou segmentaci. Pokud dochází ke změnám jasu z jedné úrovně na druhou, lze mluvit o jasových hranách. Z toho poté vyplývají jasové hraniční segmenty. Mezi modely ideální hrany řadíme skokovou, šikmou, linii a střechu. Tyto hrany jsou vyobrazeny na obrázku č. 10, kde každý obraz je znázorněn průběhem.



Obrázek 10. Modely ideální hrany: a) skoková, b) střecha, c) šikmá, d) linie [upraveno podle 26]

Detekce hran je možné rozdělit na tři fáze: filtrování, diferenciaci a detekci. Filtrování je odstranění šumu, který mohl vzniknout např. při vzorkování, kvantování ad. Diferenciaci je chápáno jako vyznačení konkrétní části obrazu. Dochází tak k zásadním změnám v jasech. Detekcí jsou vybrány konkrétní body, u kterých je intenzita nejzásadnější. [25] [26]

Hrany se nalézají díky lokálnímu předzpracování obrazu. Je vyhodnocena z amplitudy pomocí 1. derivace, která nám řekne, zda se hodnota obrazové funkce  $f(x, y)$  mění. Dle znaménka 2. derivace se stanoví, zda se bod nachází na tmavé anebo na světlé straně hrany. [25]

Z matematického hlediska musí být při změně funkce dvou proměnných uvedena parciální derivace, kde změnu takové funkce stanoví gradient. Jedná se o vektorovou veličinu označenou  $\nabla$ . Udává směr gradientu, tedy směr, kdy funkce roste a jak prudce. Gradient je dán vztahem:

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (1)$$

Velikost obrazové funkce gradientu  $|\nabla f(x, y)|$  je dána vztahem:

$$|\nabla f(x, y)| = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2} \quad (2)$$

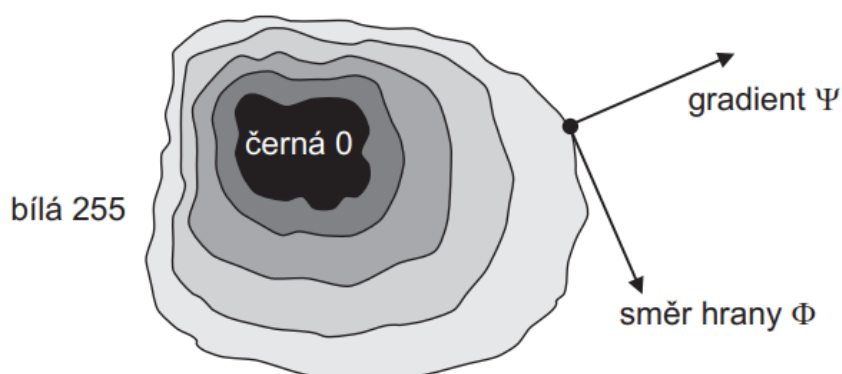
Směr gradientu  $\psi$  s úhlem  $\arg(x, y)$  v radiánech. Úhel udává poměr souřadné osy  $x$  a radiusvektor k bodu  $(x, y)$ .

$$\psi(x, y) = \arg\left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y}\right) \quad (3)$$

Nedílnou součástí detekcí hran bývá lineární Laplaceův operátor  $\nabla^2$ , díky kterému se posoudí velikost gradientu. Vztah pro Laplaceův operátor se určí z druhých parciálních derivací:

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (4)$$

Pro hranové pixely, které jsou sjednocovány a hledají hranice se vymezí směr hrany  $\phi$  kolmý na směr gradientu  $\psi$ . [25]



Obrázek 11. Směr hrany  $\phi$  kolmý na směr gradientu  $\psi$  [25]

### 2.1.1.1 Hranové detektory

Hranové detektory používají první a druhou derivaci. První derivace vytvoří gradient srovnaný s prahem. Jeho úkolem je zjistit, zda se jedná o hranu nebo ne. Druhá derivace detekuje hrany, pokud dojde k značným změnám v polaritě.

První operátory založené na derivaci/gradientu jsou velmi citlivé na šum a vytvářejí silnější hrany. V této souvislosti jsou typickými příklady detektorů hran pomocí první derivace Roberts, Prewitt a Sobel. Metoda je založená na klasickém způsobu detekce hrany hledáním maxima a minima v první derivaci obrazu. Hodnoty šedi obrazu lze detekovat pomocí diskrétní aproximace gradientu. Gradient je dvourozměrný ekvivalent první derivace. [29]

### Příklady Hranových detektorů

Robertsův detektor je jedním z prvních derivativních detektorů hran v digitálním zpracování obrazu. Provádí jednoduchý a rychlý výpočet, provádí 2D měření prostorového gradientu na obraze. Hodnoty pixelů na každém bodě na výstupu představují odhadovanou absolutní velikost prostorového operátoru. Operátor se skládá z dvojice masek  $2 \times 2$ . Robertsův křížový operátor poskytuje jednoduchou aproximaci velikosti gradientu. [29]

Sobelův operátor je jedním z nejpoužívanějších detektorů hran. Provádí 2D prostorový gradient velikosti na obraze a používá se k nalezení přibližné absolutní velikosti gradientu v každém bodě vstupního obrazu ve stupních šedi. Sobelův detektor hran používá dvojici konvolučních masek  $3 \times 3$ , z nichž jedna vyhodnocuje gradient ve směru  $x$  (sloupce) a druhá vyhodnocuje gradient ve směru  $y$  (řádky). Konvoluční maska je obecně mnohem menší než skutečný obraz. [29]

Prewittův detektor hran je vhodným způsobem odhadu velikosti a orientace hran. Je podobný sobelovu operátoru a používá se k detekci vertikálních a horizontálních hran v digitálních obrazech. Obraz by měl obsahovat ostrý přechod intenzity a je přítomen nízký šum Poissonova typu. Je vhodný pouze pro dobře kontrastní obrazy bez šumu. K nalezení velikosti vrcholového gradientu používá masky  $3 \times 3$ . [29]

### 2.1.2 Prahování - Thresholding

Je to metoda, která bývá hojně využívána díky své jednoduchosti a časové nenáročnosti. Základním principem metody prahové segmentace je klasifikovat vlastnosti pixelů nastavením různých prahových hodnot. U prahování má každý pixel takovou hodnotu intenzity, buď nad anebo pod úroveň jasu, že může být zařazen jako součást segmentace. Prahování je součástí převodu intenzitního obrazu

na binární obraz. Prahování je potřebné k vytvoření segmentační masky a černobílého obrazu našeho zájmového prvku. Lze jej provádět v reálném čase a je poměrně rychlé. Do základního konceptu prahování řadíme řezání, které má vymezit horní a dolní hranice. Je to způsob, jak izolovat rozsah intenzit pixelů. [24] [30]

Tuto metodu lze rozdělit na jednoprahovou a víceprahovou, podle počtu zvolených prahů. Při jednoprahové segmentaci je obraz rozdělený na popředí a pozadí. Je to udáno zvoleným prahem o daném stupni šedi v porovnání se stupni šedi v obrazu. Jako vzorec prahového obrázku je uvedena rovnice transformace. Rovnice takového vzorce je:

$$g(x, y) = \begin{cases} 1 & f(x, y) > T \\ 0 & f(x, y) \leq T \end{cases} \quad (5)$$

Pro tuto rovnici platí, že  $g(x, y)$  je vstupní obraz,  $f(x, y)$  je úroveň šedi bodu a  $T$  je prahová hodnota. Výběr prahové hodnoty je pro tuto metodu stěžejní. Pixely určené hodnotou 1 se rovnají objektům, ale pixely určené hodnotou 0 se rovnají pozadí. V závislosti na prahových hodnotách lze poté rozdělit prahování na globální, lokální anebo adaptivní. [25] [30]

Jak už bylo řečeno, hlavní záležitostí prahování je stanovit prahové hodnoty a úrovně. Obvykle jsou tyto úrovně nastaveny programem. Proto je vhodné využití grafu, který dokáže rozdělit hodnoty intenzit pixelů v obraze. Takový graf se jmenuje histogram. Histogramy intenzity lze použít pro segmentaci především pro odhad prahových hodnot. Pokud je histogram intenzit bimodální, tzn. že má dvouvrcholové rozložení hodnot, neboli dvě maxima jsou dostatečně od sebe vzdálená. Řešením je hledání nejnižších bodů, tedy minim. Minima jsou body představující nejmenší počet pixelů. Mezi skutečnými hraničními hodnotami leží mezní hodnoty. Aby byly mezní hodnoty lépe identifikovatelné, bývá využito filtrů např. Sobelův, Cannyho ad. [24]

### 2.1.2.1 OTSU metoda

Metoda je pojmenovaná podle Nobuyuki Otsu. Jedná se o metodu založenou na histogramech stupňů šedi obrázků. Díky maximální mezitřídí odchyly mezi popředím a pozadím vybírá vhodnou prahovou hodnotu pomocí výpočtu. Tato metoda je jednoprahová. U obrazu, kde nedochází k rovnoměrnému rozložení osvětlení, můžou být okraje mírně rozmazané a obraz se stává pozadím. Z tohoto důvodu se zavádí metoda adaptivního prahování, která rozděluje obraz na několik částí a používá metodu klouzavého průměru k výpočtu průměrné hodnoty.

Metoda dokáže vypočítat lokální prahovou hodnotu podle rozložení jasu různých oblastí obrazu. OTSU se jednoduše realizuje a vypočítává. Lze ji využít v různých oborech. Prahová segmentace je tady omezená, protože je zaměřena pouze na vlastnosti pixelů v odstínech šedi a nezohledňuje prostorové vlastnosti. Taktéž není odolná vůči šumu. Efekt segmentace je slabý u obrázků s malým rozdílem hodnot mezi popředím a pozadím. [30]

### 2.1.3 Segmentace podle regionů

V této segmentaci se vytvářejí přímo regiony namísto hran. Metoda využívá opačného přístupu, ve kde začíná uvnitř objektu a poté tzv. roste směrem ven, dokud nenarazí na hranici objektu. Zahrnuje skupinu sousedících pixelů, které jsou si podobné a jsou připojené k základnímu pixelu. Používají se i míry podobnosti, jako jsou rozdíly v úrovních šedi pro oblasti s homogenními úrovněmi šedi. Metoda vykazuje větší míru efektivity pro obraz, u kterého dochází k šumu, vůči

kterému je metoda založena na regionech odolnější. Vzhledem k tomu, že hranové operátory při šumu těžce detekují hrany, je nezbytné pro obraz detekovat jeho homogenitu neboli stejnorodost, kterými jsou myšlené zmíněné úrovně šedi, tvar, model, barva ad. Dále budou rozebrány segmentační algoritmy metody založené na regionech. [28] [30] [31]

### 2.1.3.1 Metoda Narůstání oblastí

Metoda Narůstání oblastí je jednoduchá metoda segmentace obrazu založená na regionech (pixelová). Segmentová oblast je vytvářena sousedními pixely o podobných vlastnostech. Pixely jsou spojovány a vytvářejí segmentový obraz. Metoda využívá prostorové informace a korelaci mezi jednotlivými pixely. Nejprve jsou vybrány vhodné výchozí body růstu. Body, které splňují specifické podmínky růstu, jsou sloučeny a vytvoří tak novou růstovou oblast. Ze segmentační oblasti jsou následně odstraněny slabé hrany. Výsledky jsou závislé na spojování konkrétních oblastí. Pro tuto metodu je často používán algoritmus aktivních kontur, v překladu algoritmus Aktivní kontury, který zkoumá sousední pixely počátečních bodů a opětovně určuje, zda mají být sousední pixely přidány do oblasti. [26] [30] [32]

Proces narůstání oblastí trvá, dokud jsou v obrazech přítomny oblasti, které se dají sloučit. Při řešení máme označenou obrazovou oblast, jako  $R$ . Díky procesu segmentace lze obrazovou oblast rozdělit na  $n$  podoblastí  $R_1, R_2, R_3, \dots, R_n$ , pro které platí následující podmínky:

a)  $\bigcup_{i=1}^n R_i = R$

V této podmínce je dána hypotéza, že všechny pixely jsou přiřazeny nějaké oblasti.

b)  $R_i$  je souvislá oblast, kde  $i = 1, 2, \dots, n$

Podmínka si žádá, aby body v oblasti byly souvislé.

c)  $R_i \cap R_j = \emptyset$  a pro všechny  $i \neq j$

V této podmínce nedochází k vzájemnému prolínání.

d)  $P(R_i) = TRUE$ , kde  $i = 1, 2, \dots, n$

V podmínce musí být dodrženy vlastnosti pro všechny pixely v označené oblasti.

e)  $P(R_i \cup R_j) = FALSE$ , kde  $i \neq j$

Oblasti  $R_i$  a  $R_j$  v této podmínce nejsou souvislé, co se týče vlastnosti  $P$ .


$P(R_i)$  je myšlena jako logická operace k jejíž definici dochází v  $n$  všech bodech množiny  $R_i$  a  $\emptyset$  je označena prázdná množina. [25]

Podle nastavených podmínek může nastat narůstání oblastí. Pixely mohou být přiřazovány jednotlivým oblastem, ale vše v závislosti na typu obrázku tzn. jakou má barvu, strukturu apod. Hranice regionů jsou dokonale tenké a propojené. [25] [31]

### 2.1.3.2 Metoda dělení oblastí

Metoda je protikladem k metodě narůstání oblastí. Vezmeme-li si určitou oblast, která je zcela vytvořena obrazem, může se uskutečnit dělení oblasti na jednotlivé úseky. Dělení probíhá tak dlouho, dokud se nesplní taková kritéria, která zajistí, aby vlastnosti těchto úseků byly stejné, neboli

homogenní. V takovém případě dochází k segmentaci dělením obrazové oblasti  $R$ , pro kterou platí tvrzení  $P$ , na čtyři kvadranty. Pro oblast  $R_i$ , která může být jakákoli, ale musí platit  $P(R_i) = TRUE$ . Pokud by platilo pro oblast  $P(R_i) = FALSE$ , tak musíme oblast rozdělit na menší kvadranty tzv. podkvadranty. Zprvce dojde k dělení do čtyř samostatných kvadrantů o jakékoli oblasti  $R_i$ , kde  $P(R_i) = TRUE$ . Poté se oblasti  $R_j$  a  $R_k$ , které jsou poblíž spojí, tzn. že bude platit  $P(R_j \cup R_k) = TRUE$ . Pokud už nebude možno dělit nebo slučovat oblasti, dojde k ukončení dělení. [25]



Obrázek 12. Metoda dělení oblastí [upraveno podle 26]

#### 2.1.3.3 Metoda narůstání a dělení

Dochází při ní k využívání čtvercových regionů. Pokud je region nehomogenní, pak je rozdělen na čtyři podoblasti. Pokud je region homogenní, pak dojde ke spojení do jedné. [33]

#### 2.1.3.4 Watershed metoda

Metoda watershed může být přeložena z angličtiny jako povodí. Obraz této metody je brána jako oblast nebo topografická členitost, kde jas vymezí její výšku, tzn. černá je nejnižší a bílá nejvyšší. Výsledný obraz má povahu povodí, která jsou rozdělena hrázemi. Pokud by došlo v obraze k výskytu šumu, je možné jej odstranit buď správnou předpřípravou obrázku, nebo s hrází jisté prahové výšky a nebo jinými metodami, které dokážou sloučit regiony. [33]

#### 2.1.3.5 Shluková analýza

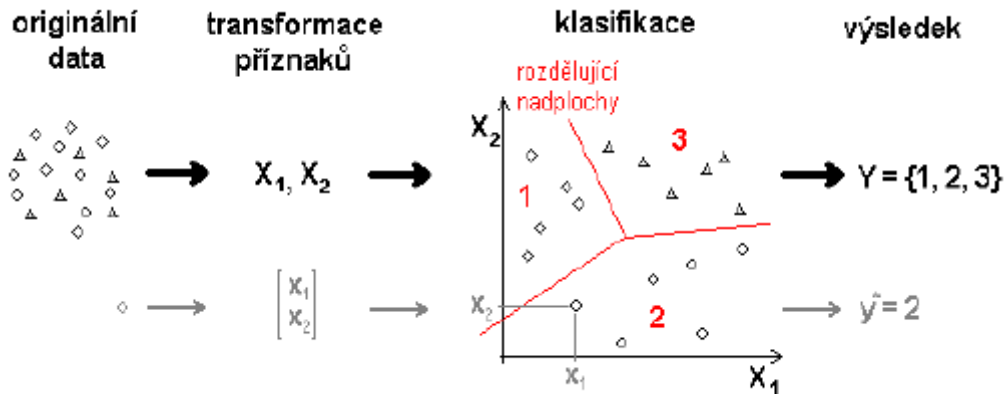
V této segmentační technice se využívají zkušební data k nalezení vzorců v obraze. Dochází ke shlukování pixelů v prostoru prvků. Hlavním úkolem shlukování je shromáždit data do tříd tak, že v rámci jedné třídy je vysoká podobnost, ale při srovnání podobnosti s ostatními třídami je tato podobnost nízká. Vzájemná podobnost se zjistí příhodným měřením vzdáleností, tzv. Euklidovská vzdálenost. Každý shluk je reprezentován svým těžištěm nebo průměrem a rozptylem. Základní metody neřízeného shlukování jsou: Fuzzy C-means (FCM), K-means a Markova náhodná pole (MRF). Mezi řízené shlukování patří umělé neuronové sítě (ANN) a Bayesovy metody. [34]

Všechny pixely představují vektor vlastností  $x = [x_1, x_2, \dots, x_N]$ . Vlastnosti mohou být např. barevná složka, povaha okolí ad. Pixely si musí být v jedné oblasti podobné, ale v jiných oblastech různé, takže vzniknou shluky v  $N$  – rozměrném prostoru. Metoda má iterativní proces, tzn. opakující se proces. Vzdálenost, kterou je potřeba vypočítat, je mezi dvěma objekty  $r$  a  $S$  popsána vztahem:



$$d(r, s) = \sqrt[k]{\sum_{i=1}^N |x_{ri} - x_{si}|^k}, \quad (6)$$

Pokud  $k = 2$ , pak se jedná o Euklidovskou vzdálenost. [33]



Obrázek 13. Metoda shlukové analýzy [33]

#### 2.1.3.5.1 Fuzzy C - Means (FCM)

Metoda Fuzzy C – Means spadá do neřízených algoritmů. Touto metodou dochází k rozdělování dat do dvou a více shluků. Každému datovému bodu je přiřazen odpovídající střed shluku. Čím blíže jsou data středu shluku, tím větší je možnost je začlenit k tomuto středu shluku. Metoda byla z hlediska času obtížná, proto pro dosažení lepších časových výsledků byly vyvinuty metody pro usnadnění řešení např. shlukovací algoritmy BCFCM (Bias corrected FCM). BCFCM pomáhá například při segmentaci mozku tím, že je velmi rychlá a má dobrou kvalitu. To může hrát zásadní roli při virtuální endoskopii mozku při segmentaci mozkových nádorů. [34]

#### 2.1.3.5.2 K - Means


K – Means podobně, jako Fuzzy C – Means hledá středy shluků. Dochází k tomu redukcí střední odchylky mezi množinou dat a vektory, s nejnižší Euklidovskou vzdáleností. Ty následně roztřídí do dopředu zadaných počtu shluků  $K: C_1, C_2, \dots, C_K$ . Množina  $x_1, x_2, \dots, x_l$  a  $K$  vyjadřují množství shluků neboli vektorů  $\mu_j, j = 1, \dots, k$ . Pro začátek vektorů  $\mu_j$  je buďto zvolená náhodná hodnota, a nebo se snaží najít konkrétní řešení, třeba i takové, které nemají předešlou zkušenost s řešením. Následně probíhá opakování tak dlouho, dokud jeden z vektorů  $\mu_j$  se nepřeklasifikuje do jiné třídy, než ve které byl doposud. Při klasifikaci jsou všechna data  $x_i$  klasifikována do tříd vektorů  $\mu_j$ . Vzor  $x_i$  je tak klasifikován do třídy  $y_i$ , udaný vztahem:

$$y_i = \operatorname{argmin} \|x_i - u_j\| \quad (7)$$

Pro přepočítávání vektoru  $\mu_j$  je dán vztah:

$$\mu_j = \frac{1}{l_j} \sum_{i=1, y_i=j}^l (x_i), \quad (8)$$

kde  $l_j$  udává počet vzorků  $x_i$ , při kterých došlo ke klasifikaci do jiné třídy. [33]



Obrázek 14. K-Means metoda: Vstup  $\mapsto$  Začátek vektoru  $\mu_j \mapsto$  Klasifikace  $\mapsto$  Přepočítání vektoru  $\mu_j \mapsto$  Klasifikace [33]

#### 2.1.3.5.3 Markova náhodná pole (MRF)


Jedná se oblast neřízených shlukových algoritmů. Výsledkem postupného začlenění prostorové informace je MRF. Problémy, které při shlukování nastávají se díky MRF snižují, protože metoda vykazuje vysokou přesnost při řešení segmentace. [34]

### 3. Rešerše metod pro identifikaci optického disku

Ačkoli je medicína velice popředu a vykazuje řadu nových trendů, na některé oční potíže dosud neexistuje taková léčba, která by nám pomohla se onemocnění zcela zbavit. Existuje pouze potlačení příznaků a ztlumení některých projevů. Jedná se o onemocnění sítnice oka. Jedná se převážně o glaukom, makulární degeneraci, hypertenzi nebo i diabetickou retinopatii. Všechny z těchto onemocnění lze ale odhalit pravidelným oftalmologickým vyšetřením. Pro oftalmology při stále zvyšujícím se počtu pacientů to často bývá nelehký úkol. Pomocí jim právě může být počítačově podporovaný diagnostický systém. [35]

Významnou roli zde hraje detekce optického disku (OD). Příkladem může být při detekci optického disku odhalení falešně pozitivních exsudátů u diabetické retinopatie, které jsou tvořeny světlými oblastmi na snímku očního pozadí. Výchozí algoritmy mohou být zásadní například při sledování cév, které vycházejí z optického disku. Také poměr a velikost C/D exkavace k terči nám řekne, zda je přítomen glaukom. U každého jedince se hodnotí velikost, tvar, barva a další parametry. [35]

Oftalmologické vyšetření přineslo v posledních letech mnoho změn. Řada přístrojů, které zobrazují lidskou sítnici má vestavěný vlastní segmentační software. Pro usnadnění práce se opouští od manuálních segmentací a aplikují se automatické segmentační algoritmy. V následujících popisech budou uvedeny rešerše metod pro segmentaci optického disku. [36]



Obrázek 15. OCT B-sken: manuální segmentace na základě regionů. Červeně je vrstva RNFL, zeleně vrstvy sítnice, tmavě modře pigmentový epitel a světle modře cévnatka [36]

Některé výzkumy automaticky měří C/D poměr z 3D snímků. Protože však 3D snímky nejsou snadno dostupné, většinou se vychází z 2D snímků fundu. [36]

### 3.1 Segmentace na základě biregionální konstrukce

Metody segmentace poměru optického disku OD a optického pohárku OC jsou v současné době rozděleny do tří kategorií na metody založené na tvaru, metody založené na aktivních obrysech a metody strojového učení. Vychází se z toho, že OD - OC má tvar kruhový až eliptický. Z tohoto důvodu se ve studiích používá tvar kruhových a eliptických transformací. Využití stacionární vlnkové transformace a algoritmu maximálního součtu pixelů cév, vytvoří automatickou oblast zájmu (ROI). Poté se k segmentaci optického disku (OD) použije transformace inverzní polarity, která dokáže pracovat s horizontálními koeficienty ROI. Kromě toho je celá oblast optického pohárku (OC) extrahována prodloužením okraje pomocí pixelu maximální cévy. OD – OC tvary nejsou ideálně kruhové nebo eliptické, proto je navržena fuzzy energeticky založená aktivní kontura, která využívá prostorové informace.

U všech metod nastává ale problém, co se týče jejich nepravidelného tvaru nehomogenity silné intenzity nebo i složitosti struktury cév v OD – OC. Jako řešení je navržen model biregionální evoluce kontur (BCE), která využívá strojové učení k segmentaci.

OD je vstupním bodem krevní cévy a je složena z velkého počtu neuronů. Jeho tvar je víceméně kulatý a liší se člověk od člověka. OC má proměnlivou velikost a leží v centru OD a je mírně snížený. Na posouzení glaukomu a dalších očních onemocnění je právě navržena metoda BCE pro segmentování OD–OC. Rozsahy intenzity OD, OC a pozadí jsou použity ke konstrukci navrženého BCE. OD může být různorodý. Okraje OD, OC a pozadí bývají neostré, díky tomu mohou být pixely v OC zaměněny s OD i s pozadím, ale i opačně. Uvažují se plošné i okrajové rysy pro sbíhavost BCE.

Při srovnávání obrázků s jinými u OD a OC není žádná jasná a zřejmá hrana, proto je tato segmentace obtížná. Model BCE segmentuje OD-OC současně. Navrhovaný model BCE konstruuje dvouúrovňové množinové funkce OD-OC. Dva počáteční obrysy jsou umístěny kolem OD-OC a přibližují se k okraji objektů současně. Jako podpora se využívá obrysových křivek. Křivky OD-OC lze vyjádřit:

$$C_{\tau}(\sigma) = \{(x, y) | (x, y, \sigma) = 0\}, \quad (9)$$

kde  $\varphi_{\tau}(x, y, \sigma)$  je funkce nastavení OD nebo OC v daném pořadí a  $\sigma$  je umělá časová proměnná. Metoda bere v úvahu intenzitu, okraje a plošné prvky.

Na snímcích sítnice s OD-OC a pozadí je nejprve extrahován jasový kanál L, pro zjednodušení analýzy. V následující rovnici je určen vztah pro jasový kanál:

$$L = \frac{\max(R, G, B) + \min(R, G, B)}{2}, \quad (10)$$

kde  $\max(R, G, B)$  a  $\min(R, G, B)$  jsou největší a nejmenší hodnoty kanálu R, G, B. Obrázek 16 pak navrhuje předzpracování obrazu pro OD-OC. [37]


Ze snímků se vymazávají rušivé elementy, jako jsou např. rušivé elementy na cévách, které jsou blízké matematické morfologii. Pokud bychom chtěli rozostřit obrysy, využívá se Gaussova funkce jádra. Funkce je potom definována:

$$G(x, y) = \frac{1}{2\pi\rho^2} e^{-(x^2+y^2)/2\rho^2}, \quad (11)$$

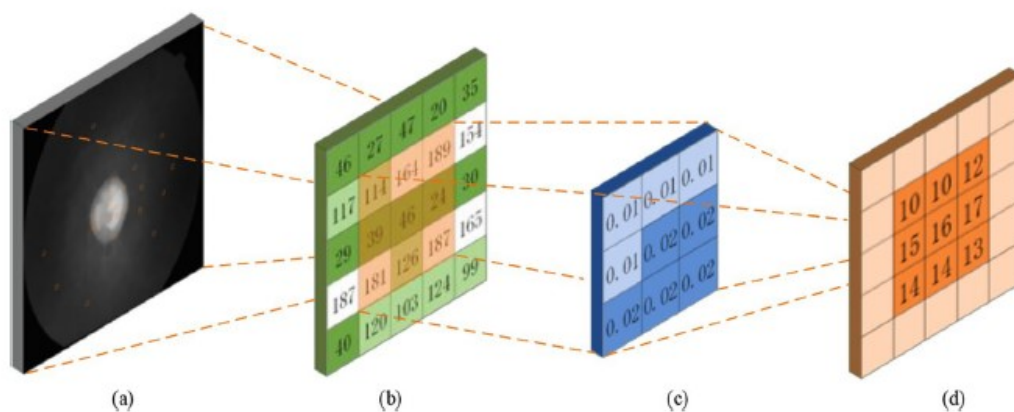
kde  $\rho$  je parametrem šířky. Pokud bychom chtěli odstranit šum ze sítnicového obrazu, využívá se konvolučního zpracování založené na metodě Gaussovy funkce jádra. Pro výpočet je dán vztah:

$$\Lambda \times G_{(1,1)} \sum_{a=0}^n \sum_{b=0}^n \Lambda_{(a,b)} G_{(1-a,1-b)}, \quad (12)$$

kde  $\Lambda$  je morfologicky zpracovaná obrazová matice a  $n \cdot n$  je velikost okna Gaussovy funkce jádra.



Obrázek 16. Výsledek předzpracování: a) původní obrázek, b) jasový kanál L, c) operace morfologie, d) konvoluční ošetření Gaussova jádra [37]




Obrázek 17. Konvoluční zpracování obrázku [37]

Na obrázku 17 (a) je vybráno 25 pixelů z (b). Pomocí Gaussovy funkce jádra je vypočítána rovnice (c), výsledkem je hladký obraz (d). [37]

V diagnostice glaukomu a dalších očních onemocnění je nyní navržen poměr C/D, neboli disk k pohárku označen jako CDR, který měří plochu na základě segmentace regionů.

$$CDR_{area} = \frac{S_{cup}}{S_{disc}}, \quad (13)$$

kde  $CDR_{area}$  je oblast poměru  $C/D$ .  $S_{cup}$  a  $S_{disc}$  poté jsou samotné oblasti pohárku a disku. CDR hodnota u zdravého oka je do 0,58. Vyšší hodnoty znamenají zvýšené riziko glaukomu.



Obrázek 18. Regiony OD a OC [37]


V Biregionální evoluci kontur založené na přístrojovém učení se nejdříve provede předzpracování obrazu a až poté se udělá analýza. Následně jsou extrahovány plošné a okrajové rysy OD-OC. CDR se vypočítá pomocí plochy extrahované oblasti OD-OC. Konkrétní kroky zpracování jsou následující: Navrhovaný algoritmus biregionální evoluce kontur OD-OC nejprve získá počáteční obrysy nastavením referenčních oblastí, poté získá intenzitu, plochu a okrajové rysy OD-OC pomocí odpovídající funkce identifikátoru hrany. Nakonec je získaná oblast OD-OC pomocí energetické funkce  $E$  s použitím rovnice:

$$E_{\tau} = \lambda_{\tau} \operatorname{div} \left( \xi_p (|\nabla \varphi_{\tau}|) \right) \nabla \varphi_{\tau} + \alpha_{\tau} \delta_{\tau}(\varphi_{\tau}) \operatorname{div} \left( \frac{\nabla \varphi_{\tau}}{|\nabla \varphi_{\tau}|} \right) + \beta_{\tau} \delta_{\varepsilon}(\varphi_{\tau}), \quad (14)$$

kde  $\xi_p$  je odvozena z Diracovy delta funkce  $\alpha$ ,  $\beta$  a  $\lambda$  jsou konstanty.

Funkce indikátoru hrany z přístrojového učení vytvoří algoritmus tím, že nejprve nastaví referenční oblasti v OD, OC a pozadí v obrazech sítnice. Poté je referenční oblast extrahována jako tréninkový vzorek. Na tomto základě je zkonstruován tréninkový model. Dále se vytvoří fuzzy vektor a jeho maximální hodnota se použije k definování tříd objektů v tréninkovém modelu. Nakonec se podle získaného fuzzy vektoru vypočítá funkce indikátoru hrany.

Výsledná biregionální obrysová energetická funkce  $E$  pro segmentaci OD a OC, je dána časovou složitostí algoritmu  $O(n^2)$ , kde  $n$  je počet biregionálních evolucí kontur, které se v algoritmu vyskytují. Experimentální výsledky jsou pak znázorněny na obrázku č. 19.



Obrázek 19. Experimentální výsledky navrhované metody: a) původní obraz, b) předzpracovaný obraz, c) referenční oblast, d) Gaussova funkce jádra, e) počáteční obrysy biregionální evoluce kontur, f) a g) biregionální evoluce kontur, h) konečná segmentace [37]

### 3.2 Segmentace optického disku prahováním

Prahové algoritmy segmentují obraz na základě kvantifikovatelných vlastností. Těmito vlastnostmi je intenzita obrazu, velikost gradientu a rozdělení pixelů podle definovaného prahu. Ramzan s kolektivem a Khalil s kolektivem navrhli tzv. metody pro extrakci poměru exkavace k disku C/D pomocí segmentace vnitřní limitující membrány (ILM). U segmentace ILM byla pomocí prahu o určité intenzitě vymezována a aplikována k výpočtu přibližných hodnot funkce, které tak vyplní mezery na každém obrázku, tedy nalezení chybějících bodů, odstranění vzdálených bodů ad. Pigmentový epitel sítnice (RPE) byl získán pomocí Otsuovy metody, který se aplikoval na každý obrázek. Podle vzdáleností všech středů objektů byla pomocí prahování odstraněna rozšířená oblast exkavace. [36]

### 3.3 Segmentace optického disku detekcí hran

Boyer a kolektiv se snažili rozšířit Markovův model, který využíval kontrastů k extrakci sítnicovo – cévnatkové hranici. Nejprve našli hranici sklivce a sítnice pomocí prahu založeného na hranách.

Pod sítnicovo - sklivcovou hranicí se na snímcích nacházely dvě silné tmavé a jedna světlá hrana, které popisovaly vnější hranice optického nervu (ON).

Další práce zahrnovaly metody na detekci hran pomocí Cannyho detektoru. Vyfiltrováním s použitím lineární metody nejmenších čtverců byl každý B - sken přemapován do 3D obrazu. Výsledná mapa byla nakonec odvozena z mapy hran a gradientů intenzity. Místa s velkou intenzitou gradientu detekovali až oblast lamina cribrosa neboli ploténky kosti čichové.

### 3.4 Segmentace na základě strukturovaného učení

*Morales a kol.* rozdělil segmentační metody do tří kategorií na metody založené na šablonách, metody založené na deformovatelném modelu a metody založené na morfologii. V metodách vycházejících z šablon jsou regiony oblastí extrahovány pomocí prahování. Poté se provede Houghova transformace, aby se výsledek zobrazil, jako kruh s vysokou intenzitou. Kruh, který má nejvyšší průměrnou intenzitu, se vybere jako OD. Následně je použit Prewittův detektor hran k získání hranice OD a kruhová Houghova transformace je použita k dokončení finální segmentace optického disku. *Lalonde a kol.* vybrali Cannyho okrajový detektor k extrakci okrajů OD a je použita Hausdorffova metoda.


U metod založených na deformovatelném modelu je použita barevná matematická morfologie k odstranění krevních cév a zafixování regionu OD. *Lowell a kol.* navrhl metodu segmentace OD pomocí modelu deformovatelného obrysu. Vychází z využití specifických vlastností, jako jsou vyblednutí, síla okrajů nebo i peripapilární atrofie.

Pro metody založené na morfologii *Walter a kol.* extrahovali OD pomocí Watershed transformace za předpokladu, že OD představuje světlou oblast. Watershed algoritmus je aplikován na regiony je aplikováno pro extrakci oblastí povodí, poté je prováděna rozlišování oblasti pro výběr pixelů, které patří k OD na základě průměrné intenzity oblasti.

Z těchto výzkumů se vycházelo pro další studia a návrhy metod pro detekci OD. Pro další studium je navrhovaná metoda, která využívá okrajové informace snímku očního pozadí k detekci OD. Liší se od klasické metody, která využívala k detekci hran např. Prewittův hranový detektor. Vychází z toho, že vaskulární okraje na snímku očního pozadí jsou velice silné. V takovém případě u klasických detektorů dochází k detekování mnoho vaskulárních okrajů, ale bez OD.

V některých případech se využívá výběr konkrétních kanálů, ale nejeví se to jako ideální zobrazení výsledků. Vzhledem k variabilitě snímku očního pozadí žádná individuální metoda nezaručuje optimální výsledek. V obrázku 20 je využit Prewittův hranový detektor. [35]






Obrázek 20. a) snímek optického nervu, b) zelený kanál, c) červený kanál, d) strukturované okraje, e) hrany získané aplikací Prewittovým operátorem na zelený kanál, f) hrany získané aplikací Prewittovým operátorem na červený kanál [35]

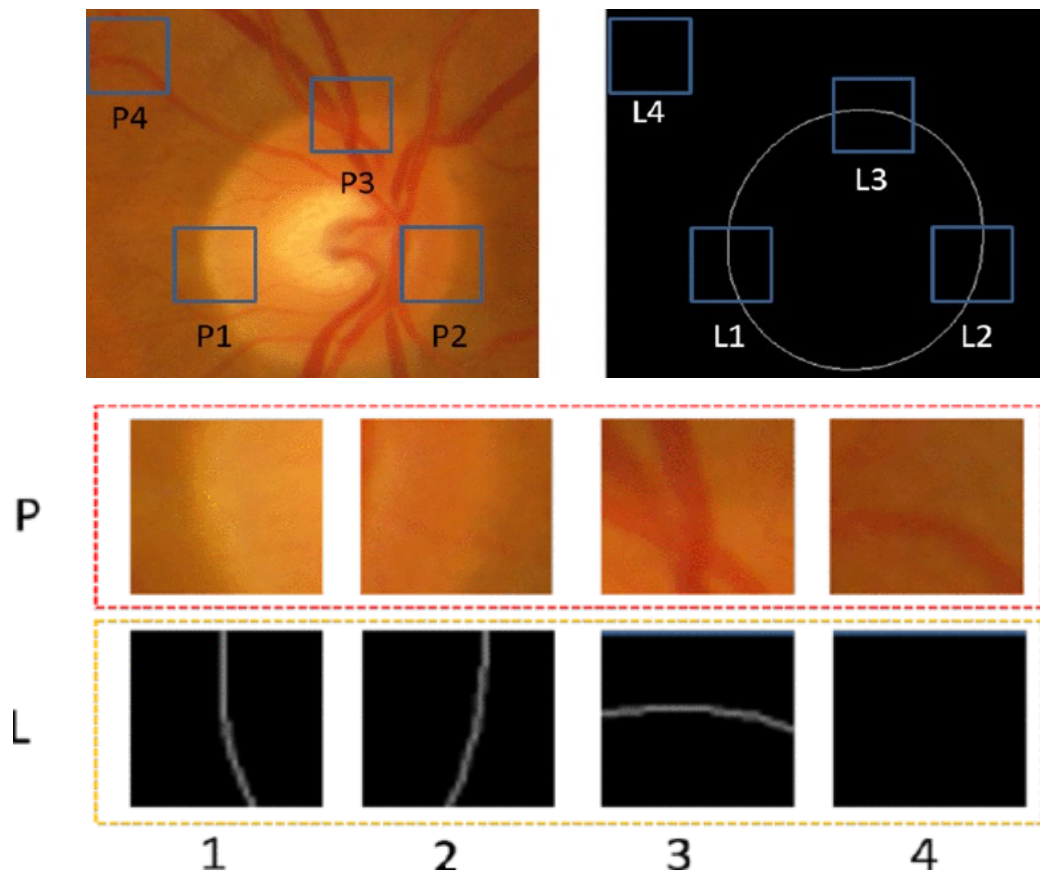
V tomto výzkumu bývá využíváno strukturované učení, které pomáhá detekovat informace o hranách, konkrétně o vnější hraně. Snímek očního pozadí lze jednoduše vzít a použít jako vstup hranového detektoru. Pro tuto práci byl využit Random Forest detektor pro strukturované učení, který má schopnost automaticky vybrat optimální sadu funkcí a z původního snímku očního pozadí vybírá všechny tři kanály tj. červený, zelený a modrý, aby výsledný detektor mohl nejlépe zachytit hranu.

Pro realizaci segmentace optického disku se za prvé musí oříznout dílčí snímky a lokalizuje se OD. Dojde k využití korelačního filtru, který používá Laplaciána nebo Gausse a sloučí klíčové prvky struktury OD pro detekci bodu umístěného v OD. Dílčí obraz s vnějším průměrem  $300 \times 300$  je poté oříznut na základě detekovaného bodu na obrázku č. 21. Okrajová mapa je získána z obrazu a může být použito prahování. Tímto dojde k získání binárního obrazu a Houghova transformace nahradí hranice OD.



Obrázek 21. Proces oříznutí dílčího snímku OD [35]

Strukturované učení mapuje, kde vstupním nebo výstupním prostorem mohou být libovolně složité reprezentace, jako jsou řetězce, sekvence, grafy, pozice objektů, ohraničující rámečky atd. Často obsahují známé vzory, jako je oblouk. Na obrázku č. 22 jsou P1, P2, P3 jsou políčka s vnějšími okraji, P4 je záplata bez vnější hrany. L1, L2, L3 a L4 jsou odpovídající místní segmentační masky. Výstupní prostor strukturovaného učení může být libovolně složitá reprezentace. Detekce hrany OD pomocí strukturovaného učení může být vyjádřen jako odhad lokálních segmentačních masek daných polí vstupního obrazu.




Obrázek 22. P - políčka s vnějšími okraji objektů, L - odpovídající segmentační masky [35]

Pro detekci hran je v této studii je využíváno (Structured Edge Detection Toolbox) vyvinutý Dollárem k získání hranové mapy OD. Ořízne se záplata. Poté je extrahován příznakový vektor, který reprezentuje záplatu, aby náhodná doménová struktura mohla rozpoznat vzor v záplatě. Konečný výstup je zprůměrován místní segmentací na každé části. Posuvné okno s výchozí velikostí  $32 \times 32$  je po snímku očního pozadí obraz pro každé okno, aby se dosáhlo mapy okrajů OD.

Prahování je vzhledem k obrázku ve stupních šedi použito k vytvoření binárního obrazu. Metoda prahování nahradí každý pixel v obrázku černým pixelem, pokud je intenzita  $(x, y)$  menší než nějaká pevná hodnota prahu  $T$ , nebo bílý pixel, pokud je intenzita obrazu větší než tato hodnota. To lze definovat jako:

$$BW(x, y) = \begin{cases} 1 & \text{pokud } I(x, y) > T \\ 0 & \text{ostatní} \end{cases} \quad (15)$$

V tomto příkladě je využita Otsuova metoda, která rozhodne o výběru prahu  $T$ . Aby došlo k zachování hranice OD, tak se sníží práh  $T$  vynásobením faktoru  $f$  menším než 1. Obr. č. 23 ukazuje binární obraz, kde  $f$  1, 0.618, 0.4. Můžeme vidět, že pokud faktor  $f$  je menší, zůstává více informací o vnější hraně zachováno, ale taktéž může být zahrnuto více falešných okrajů. [35]



Obrázek 23. Různé výsledky pro nastavení hodnot  $f$ : a)  $f=1$ , b)  $f=0,618$ , c)  $f=0,4$  [35]


Kruhová Houghova transformace se snaží nalézt kruhové vzory. Je definována takto:

$$(C_x, C_y, r) = CHT(I_{BW}, r_{min}, r_{max}), \quad (16)$$

kde  $I_{BW}$  je binární obraz a  $r_{min}, r_{max}$  je vyhledávací rozsah poloměrů.  $c_x, c_y$  a  $r$  je středová poloha a poloměr získaný kruhovou Houghovou transformací.  $r_{min}, r_{max}$  jsou důležité parametry k vymezení rozsahu hledání kruhové Houghovy transformace. Předpokladem je velikost obrázku fundu  $s_x \times s_y$  a nastavení rovnice  $r_{min}, r_{max}$  na základě této studie:

$$\begin{aligned} r_{min} &= 0,013 \times s_{max} - 0,01 \times s_{min} + 37 \\ r_{max} &= 0,013 \times s_{max} - 0,01 \times s_{min} + 37 \end{aligned} \quad (17)$$

kde platí  $s_{max} = \max[s_x, s_y]$  a  $s_{min} = \min[s_x, s_y]$ . Pokud by byla velikost obrázku fundu  $640 \times 480$ , pak  $s_{max} = 640, s_{min} = 480$ . Na obrázku č. 24 je červený kroužek, který je aproximován hranicí OD detekované kruhovou Houghovou transformací. [35]



Obrázek 24. a) Kruhová aproximace hranice vnějšího průměru, b) efekt překrytí kruhu na snímku očního pozadí [35]

## 4. Analýza retinálních dat z variabilních zobrazovacích modalit


Pro analýzu retinálních dat byla využita sada anonymních snímků z různých zdrojů. Na snímcích je pomocí fundus kamery zobrazeno oční pozadí. Docházelo k porovnávání snímků dospělých lidí, ale i dětí. Názvy jednotlivých zdrojů jsou následující: Data Drive, Data Stare, Phoenix ICON, Clarity RetCam 3 a Envision Retcam 3.

Data Drive jsou snímky pořízené v Nizozemsku u lidí, jejímž screeningem se snažili zaznamenat diabetickou retinopatii. Z databáze fotografií, které byly volně dostupné na internetu jsme vybrali 40 snímků očního pozadí. Data Stare jsou výsledkem strukturální analýzy sítnice. Data poskytlo Shiley Eye Centrum Kalifornské univerzity v San Diegu s volnou dostupností na internetu. Z dané databáze jsme vybrali 50 snímků sítnice.

Centrum pro děti s vadami zraku Oční kliniky Fakultní nemocnice Ostrava poskytlo snímky anonymních dětí z databáze Phoenix ICON, Clarity RetCam3 a Envision Retcam3. Jednalo se o snímky předčasně narozených dětí s očním onemocněním Retinopatie nedonošených (ROP). Ze snímků, které nám byly poskytnuty, jsme u Clarity RetCam3 použili 47 obrázků, z Envision RetCam3 49 obrázků a Phoenix ICON 46 obrázků. Ukázky z jednotlivých databází jsou vidět na následujících obrázcích.



Obrázek 25. Ukázka snímků z databáze Drive



Obrázek 26. Ukázka snímků z databáze Stare





Obrázek 28. Ukázka snímků z databáze Envision RetCam3



Obrázek 27. Ukázka snímků z databáze Clarity RetCam3



Obrázek 29. Ukázka snímků z databáze Phoenix ICON

Rozdíly mezi jednotlivými datasey jsou uvedeny v tabulce č.1.

Tabulka 1: Technické parametry snímků

Zdroje dat	Rozlišení snímků v pixelech	Bitová hloubka	Jasové úrovně
Data Drive	565 X 584	24	16 777 216
Data Stare	700 X 605	8	256
Clarity RetCam3	640 X 480	24	16 777 216
Envision RetCam 3	1440 X 1080	24	16 777 216
Phoenix ICON	1240 X 1240	24	16 777 216

Pixel je nejmenší jednotkou obrázku. Každý pixel udává hodnotu úměrnou intenzitě světla v daném bodě. Pokud by měl pixel hodnotu logické 0, znamenalo by to, že se v daném bodě vytvoří černá barva. Pokud by měl pixel hodnotu logické 1, znamenalo by to, že se v daném bodě vytvoří bílá barva. Celkový počet pixelů je vyjádřen maticí, kde první hodnota udává počet řádků neboli šířku a druhá počet sloupců neboli výšku.

$$\text{Celkový počet pixelů} = \text{počet řádků} \times \text{počet sloupců} \quad (18)$$

Dalším parametrem uvedeným v tabulce je bitová hloubka. Bity označují počet bitů na pixel neboli počet různých barev v obrázků. Celkový počet kombinací barev v obrázku, který by šel vytvořit by byl dán vztahem:

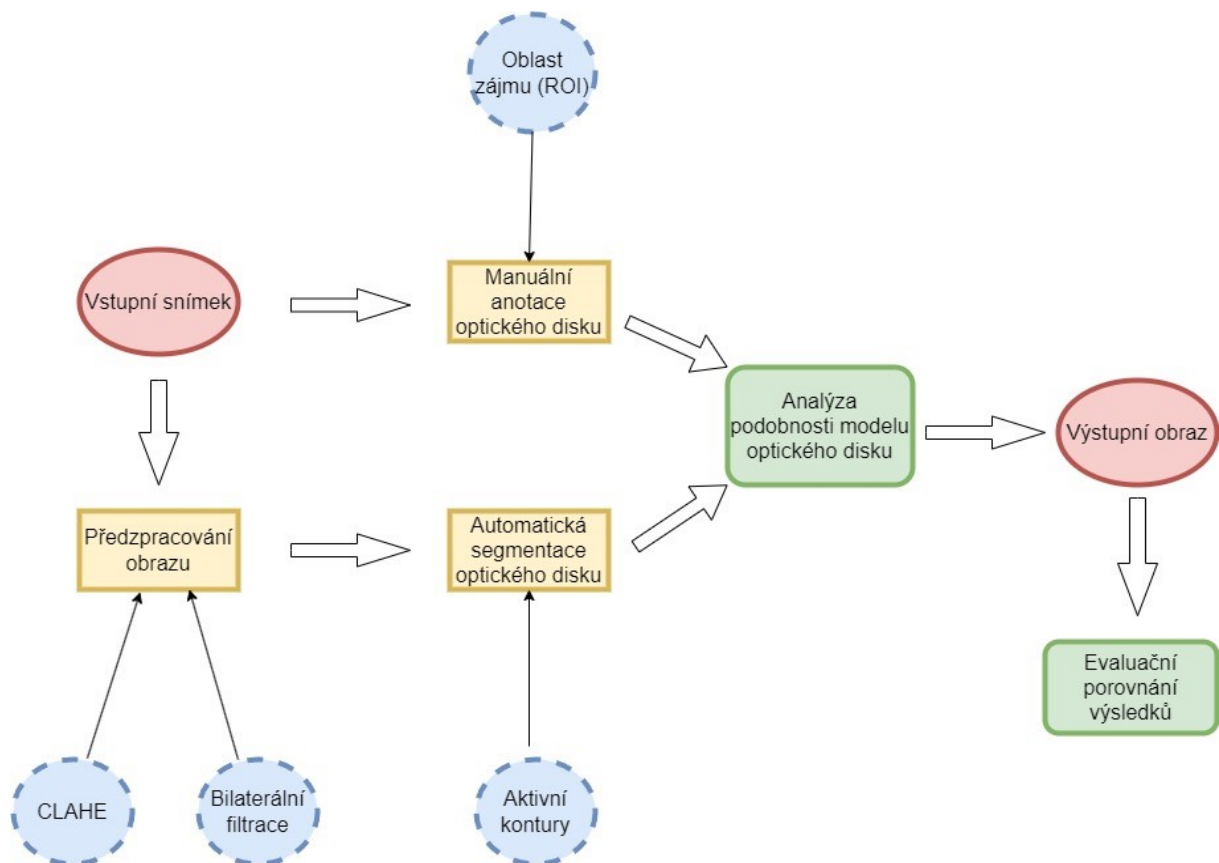
$$\text{Počet barev} = (2)^{bpp} \quad (19)$$

kde bpp označuje bity na pixel. Výsledná hodnota roste exponenciálně. Pokud má například jasová úroveň hodnotu 256, znamená to, že má 256 různých barev. [38]

## 5. Návrh algoritmu pro detekci optického disku

Algoritmus je tvořen několika procesy, které jsou znázorněny v následujícím blokovém schématu. Snímky pořízené fundus kamerami jsou postupně zpracovávány metodou manuální anotace s využitím oblasti zájmu ROI. Poté je stejný snímek předzpracován a automatickou metodou segmentace na základě metody aktivních kontur bez hran, je provedeno ohraničení optického disku. Výsledné binární obrazy obou metod jsou fúzovány. Vznikne výstupní snímek, ve kterém jsou barevně odlišeny rozdíly manuální anotace a automatické segmentace. Na závěr dochází k porovnání výsledků těchto obrazů pomocí evaluačních parametrů.


Každý snímek musí být individuálně zpracovaný, jelikož snímky nejsou stejné. Je to dáno tím, že snímky byly vyfoceny s různým rozlišením, kontrastem a osvětlením. Také hraje roli to, že snímky byly pořizovány jak u dospělých, tak i u dětí, kde spolupráce není adekvátní.



Obrázek 30. Blokové schéma návrhu algoritmu pro detekci a extrakci optického disku

## 5.1 Manuální anotace optického disku


Cílem manuální anotace bylo vytvoření zlatého standardu, který se překryje s výsledkem segmentace. Princip spočíval v manuálním ohraničení optického disku. Nejprve se musel zvolit počet oblastí zájmů nROI a poté tvar, který by co nejpřesněji ohraničil optický disk. Vybíralo se z obdélníkového, elipsoidního, nepravidelného mnohoúhelníku a volně definovaného tvaru.



Obrázek 31. a) obdélníkový, b) elipsoidní, c) nepravidelný mnohoúhelník, d) volně definovatelný

Jak je zřejmé z jednotlivých snímků, nejpřesněji ohraničený tvar optického disku je pomocí elipsoidního tvaru a tvaru nepravidelného mnohoúhelníku. Výsledkem této anotace je binární obraz a originální obraz překrytý s binární maskou. Výsledná binární maska je dále využívána pro závěrečné vyhodnocování rozdílností oproti automatické segmentaci.





Obrázek 32. Ukázka manuální anotace s originálem překrytým s binární maskou a binární maska

## 5.2 Předzpracování obrazu

Poté co je snímek převedený do digitální formy, může být jeho kvalita znehodnocena z různých důvodů. Protože je však potřeba na snímcích zvýraznit optický disk od zbylého oční pozadí, využívá se různých metod, které by zachovaly kvalitu vstupního snímku. Hlavním úkolem těchto metod je potlačit šum, zvýšit kontrast a zvýraznit detaily neboli hrany oblasti zájmu, které jsou hůře viditelné například kvůli špatným světelným podmínkám. Se zvýrazněnými objekty pomocí předzpracovaného obrazu se lépe vyhodnocuje získaný obraz a výsledky segmentace jsou kvalitnější. Na obrázku č. 33 je znázorněno blokové schéma procesu předzpracování obrazu. [33]



Obrázek 33. Blokové schéma předzpracování obrazu

### 5.2.1 Výběr chromizační složky


Barevné snímky jsou takové, u kterých vektor různých hodnot, např. každá barevná vrstva na snímku, se shoduje s každou dvojicí plošných souřadnic  $(x, y)$ . Samostatný monochromatický obraz je dán pouze jednou obrazovou funkcí  $f(x, y)$ . Samotná barva obrazu reprezentuje elektromagnetické vlnění, které je odrážené v odlišných vlnových délkách. Při zpracování obrazu pomocí počítače není možné zpracovávat každou vlnovou délku. Barevný snímek je tvořen třemi spektrálními složkami, které se smísí. Složky těchto spekter jsou označeny jako RGB:

1.  $R$  = červená barva s vlnovou délkou  $\lambda = 700 \text{ nm}$
2.  $G$  = zelená barva s vlnovou délkou  $\lambda = 546,1 \text{ nm}$
3.  $B$  = modrá barva s vlnovou délkou  $\lambda = 435,8 \text{ nm}$  [25]

Extrakce červené a zelené složky je popsána následujícím algoritmem:

```
model_RG(:, :, 1) = i(:, :, 1);  
model_RG(:, :, 2) = i(:, :, 2);  
model_RG(:, :, 3) = zeros(r, s);
```

Cílem bylo co nejvíce zvýraznit optický disk oproti pozadí. Tím, že si byla modrá složka RGB modelu nejvíce podobná s pozadím, muselo dojít k jejímu odstranění.



Obrázek 34. Výběr chromizačních složek z databáze Envision RetCam3


### 5.2.2 Monochromatické operace

Pokud by mělo dojít k vytvoření monochromatického obrazu, je zapotřebí všechny složky R,G,B převést do stupňů šedi. Převod snímku do stupňů šedi ponechá ostré hrany a další výhodou je, že se se snímkem ve stupních šedi lépe dále pracuje. Mapa barev je zadaná jako číselná matice v 3D RGB modelu. Pomocí algoritmu *rgb2gray* jsou hodnoty RGB převedeny na snímek ve stupních šedi vytvořením váženého součtu:

$$0,2989 \cdot R + 0,5870 \cdot G + 0,1140 \cdot B \quad (20)$$

Vzhledem k odstranění modré složky, byl výsledný algoritmus poupraven. Algoritmus pak nabýval rozměrů 2D matice s váženým součtem:

$$0,2989 \cdot R + 0,5870 \cdot G \quad [39] \quad (21)$$



Obrázek 35. Převedení nativního snímku z databáze Stare do stupňů šedi

### 5.2.3 Ekvalizace histogramu

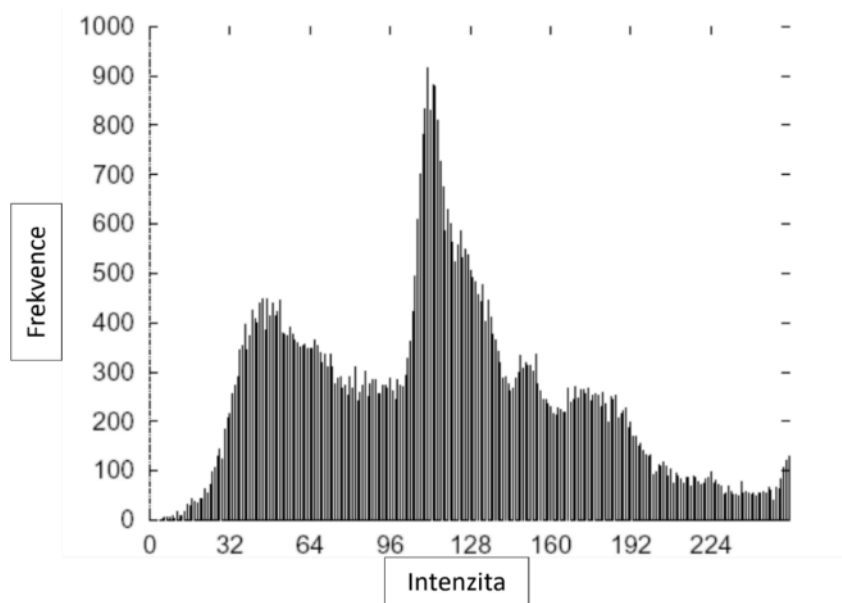
Pro pochopení ekvalizace histogramu je dobré znát pojem histogram. Histogram stanovuje údaje o jasových informacích na snímku. Histogram je diskretní funkcí v digitálním snímku, pokud rozsah hodnot jasu je v rozmezí  $\langle 0, L - 1 \rangle$ . Potom můžeme uvést vzorec:

$$h(r_k) = n_k \quad (22)$$

$r_k$  je  $k$ -tá úroveň šedi a  $n_k$  udává počet pixelů na snímku s úrovní šedi  $r_k$ . Normalizovaný tvar histogramu je dán vztahem

$$p(r_k) = \frac{n_k}{n} n \quad (23)$$

kde  $n$  je celkový počet pixelů na snímku.  $p(r_k)$  označuje pravděpodobnost výskytu úrovní šedi  $r_k$ . Histogramem se rozumí hustota pravděpodobnosti rozdělení jasu s podmínkou, že všechny prvky v normalizovaném histogramu jsou po sečtení rovny 1. Histogram je tvořen sloupcovým grafem, kde je osa  $x$  vyjádřením jasových úrovní a osa  $y$  je  $p(r_k)$  nebo  $h(r_k)$ . Ukázka histogramu je na obrázku 36. Jednomu histogramu může odpovídat více snímků, naopak jednomu snímku je přiřčen pouze jeden histogram.



Obrázek 36. Histogram jasu  $L=256$  jasových úrovní [25]

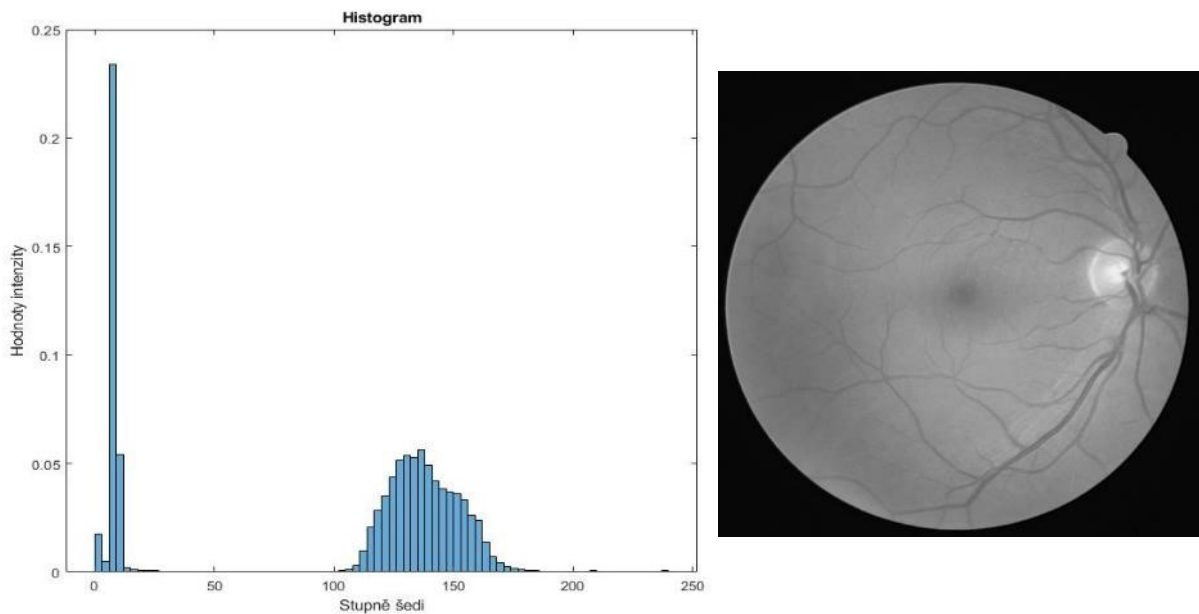
Ekvalizací histogramu je myšleno srovnání všech jasových intenzit. Pokud bude využito spojitě funkce, kde proměnné budou nabývat intervalu  $r \in \langle 0,1 \rangle$ , pak hodnota  $r = 0$  se vztahuje k černé barvě, hodnota  $r=1$  se vztahuje k bílé barvě. Transformace se zjišťuje pro všechny  $r$  z intervalu  $r \in \langle 0,1 \rangle$  a je dána jako  $s = T(r)$  pro  $0 \leq r \leq 1$ . Pro transformační funkci je nezbytné, aby splňovala "tzv. podmínky jednoznačnosti:

- a)  $T(r)$  je jednoznačně a monotónně rostoucí v interval  $0 \leq r \leq 1$
- b)  $0 \leq T(r) \leq 1$  pro  $0 \leq r \leq 1$ "

Podmínka jednoznačnosti  $T(r)$  je nezbytná k vytvoření zpětné transformace. Hodnoty výstupního obrazu jsou sestaveny na základě podmínky monotónnosti. Zpětná transformace je pak definována:

$$r = T^{-1}(s) \quad (24)$$

Jasové intenzity obrazu jsou přibližně vyrovnané poté, co jsou jasové stupnice transformovány. Proto je ekvalizace histogramu posuzována jako vyrovnání histogramu. Pro maxima histogramu jsou zvýšené kontrasty, zatímco pro minima histogramu jsou kontrasty sníženy. [25]




Obrázek 37. Histogram u šedotonového snímku z databáze Drive

### 5.2.3.1 CLAHE

Jedná se o techniku, která vychází z Adaptivní ekvalizace histogramu (AHE). Hlavním přínosem při zpracování snímku spočívá ve zlepšení kontrastu. Pomocí několika vypočítaných histogramů dojde k rozložení jasových intenzit tak, že selepší kontrast a jsou lépe vymezeny hrany objektů na snímku. Kontrastně limitovaná adaptivní ekvalizace histogramu (CLAHE) oproti metodě AHE zabraňuje, aby docházelo ke zvyšování šumu.

Algoritmus CLAHE je tvořen 3 částmi: generování dlaždic, ekvalizaci histogramu a bilineární interpolaci. Vstupní snímek se rozdělí na dlaždice. Dříve určený limit klipu vyrovná histogram pro každou dlaždici. Vyrovnání histogramu tvoří jeho výpočet, výpočet přebytku, přebytečné rozdělení, přerozdělení přebytku a škálování a mapování díky kumulativní distribuční funkce CDF. Histogram spočítá každou dlaždici jako sadu oddílů s tím, že hodnoty oddílů, které jsou vyšší než limit klipu se shlukují a šíří se dále do jiných oddílů. Hodnoty CDF jsou škálovány a mapovány pomocí vstupních hodnot pixelů na snímku. [40]




Obrázek 38. Ukázka CLAHE u databáze Drive



## 5.2.4 Jasová transformace

Jasové transformace bývají nejčastěji rozdělené podle velikosti v oblasti kolem vyšetřovaného bodu. Mezi tyto transformace patří globální jasová transformace, při které se hodnotí, jaká nová hodnota pixelu vznikne spočítáním z hodnot kompletního obrazu. Druhou transformací je lokální jasová transformace. Lokální transformace je taková, při které se nová hodnota pixelu spočítá z lokální oblasti kolem pixelu. Třetí transformací je bodová jasová transformace, kde nová hodnota pixelu je spočítána pouze z hodnot samotného pixelu. [41]




Obrázek 39. Globální, lokální a bodová transformace [41]

Jasová korekce má za úkol odstranit nebo také potlačit chyby při snímání a digitalizaci snímku. Jelikož snímek nebývá ve všech místech stejně osvětlený, musí být korekce upravována sčítáním nebo odečítáním jasových úrovní. Různé aspekty, jako jsou např. zvýšení nebo snížení kontrastu jsou chápány jako změny v jasové stupnici. Transformace takové stupnice jasu je určena vztahem:

$$q = T(p), \quad (25)$$

kde  $p$  je výchozí stupnice jasu,  $q$  je nová stupnice jasu a  $T$  je transformace. [42]



Obrázek 40. Jasová transformace Phoenix ICON: a) nativní snímek, b) snímek po převedení do stupňů šedi, c) jasová transformace

### 5.2.5 Filtrace obrazu

Filtrace obrazu je chápána jako změna obrazu, kdy jsou hodnoty jasu pixelů u vstupního obrazu transformovány na hodnoty jasu pixelu u výstupního obrazu. Filtraci lze použít jak na celý obraz, tak i pouze na oblast zájmu. Jeho hlavním přínosem je zlepšení kvality obrazu. [25]

Filtrace bývá vnímána jako vyhlazení obrazu. Její snahou je buď zvýraznit nebo potlačit údaje na snímku. Snímek může být zpracováván různými filtry. Filtrace zajišťuje fungování v rámci intenzity bodu a oblastí kolem něj. Proto dochází k využití metod, které vycházejí z vah v blízkosti daného bodu nebo metod, které mění intenzitu daného bodu. Tyto metody jsou lineární. Oproti tomu intenzita nelineární funguje u různých intenzit dané oblasti v blízkosti daného bodu. [43]

#### 5.2.5.1 Bilaterální filtr

Bilaterální filtr (BF) je asi nejjednodušším a neúčinnějším filtrem pro vyhlazování obrazu, který dokáže vyhladit obraz, aniž by došlo k narušení jeho hran. Bilaterální filtrování je filtrování obrazu procesem váženého průměru, kde je každý pixel ve filtrovaném obraze odvozen z průměru vážených sousedních pixelů původního obrazu. Bilaterální filtr při výběru vhodných vah zohledňuje jak geometrickou blízkost, tak fotometrickou podobnost mezi pixely. Dokáže tedy vyhladit barvy a zachovat hrany způsobem, který je vyladěn na lidské vnímání.

Obecně lze nejmodernější BF rozdělit na kvantizační, aproximační, transformační a histogramové. BF založený na kvantizaci nejprve kvantizuje rozsah intenzity do malé množiny úrovní, poté každá úroveň projde bilaterální filtrací pomocí konvolucí. BF založený na aproximaci využívá posunutelné aproximace Gaussových prostorových nebo rozsahových jader pro bilaterální filtrování. BF založený na transformaci převádí proces bilaterální filtrace na vysokodimenzionální konvoluci pro urychlení procesu. Jelikož je BF považováno za operátor, který působí na lokální histogram, je BF založený také na histogramu. [44]

Pro zachování hran při vyhlazování obrazu využívá BF rozsahu jádra. Vyhlazený obraz se spočítá:

$$S_x = \eta_x \sum_{y \in \omega_x} \psi(y-x) \phi(f(y) - f(x)) f(y), \quad (26)$$

kde  $\eta$  a  $\psi$  jsou normalizační faktory. Gaussovo prostorové jádro je dáno:

$$\eta_x = \frac{1}{\sum_{y \in \omega_x} \psi(y-x) \phi(f(y) - f(x)) f(y)}, \quad (27)$$

$$\psi(t) = \exp\left(-\frac{t^2}{2r^2}\right), \quad (28)$$

kde  $r$  je směrodatná odchylka Gaussova prostorového jádra. Bilaterální filtr je pak definován:

$$S_x = \eta_x \sum_{y \in \omega_x} \phi(f(y) - f(x)) f(y), \quad (29)$$


kde  $\eta$  a  $\phi$  jsou dány vztahy:

$$\eta_x = \frac{1}{\sum_{y \in \omega_x} \phi(f(y) - f(x))}, \quad (30)$$

$$\phi(s) = \exp\left(-\frac{s^2}{2\rho^2}\right). \quad (31)$$



Efekt vyhlazení je řízen parametrem  $\rho$ . Čím menší velikost parametru  $\rho$  je, tím je menší vyhlazení. Větší velikost  $\rho$  vyhlazuje více, ale na druhou stranu dochází k rozmazávání informací. [45]



Obrázek 41. Bilaterální filtrace u databáze Clarity RetCam3

### 5.3 Automatická segmentace optického disku

Hlavním cílem samotné segmentace je vymezit oblast zájmu ROI na snímku. Segmentace se skládá z nejrůznějších procesů, které musí zajistit, aby docházelo k vyhodnocení snímku pouze v jeho konkrétní části. Při segmentaci musí dojít k rozčlenění jednotlivých pixelů do konkrétních oblastí v obraze. Při analýze jednotlivých objektů jsou data přerozděleny do dílčích segmentů. Za takových okolností se využívá vyšších algoritmů, které se snaží porozumět obrazu. Na závěr jsou jednotlivé objekty hodnoceny. [26]

Po předzpracování obrazu byl v MATLABu využit příkaz `uint8`. Tento příkaz pracuje s pixely v rozmezí 0 – 255 a tím odpovídá 8 bitům. Příkaz se využívá proto, aby bylo zpracování obrázků rychlejší a jednodušší.

#### 5.3.1 Aktivní kontury bez hran

Jedná se o postupné modelování uzavřené křivky neboli kontury. Křivka se postupně transformuje a deformuje tak, že se dostane až na hranu objektu zájmu. Aktivní kontura se tak mění s využitím vnitřních, obrazových a vnějších sil. Vnitřní síly jsou parametrem, který se snaží o lehkost a nenáročnost průběhu. Obrazové síly se snaží, aby tvar aktivní kontury mířil směrem ke hraně objektu zájmu. Vnější síly udávají finální stav vzhledem k původnímu umístění kontury. Kontura je definována diskrétně:

$$v_n = [x_n, y_n], \text{ pro } n = 0, 1, \dots, N \quad (32)$$

Konečný stav aktivní kontury odpovídá lokálnímu minimu energie kontury a je dána vztahem:

$$E_S = \sum_{n=1}^N E_N\{v_n\} + \sum_{n=1}^N E_I\{v_n\} + \sum_{n=1}^N E_T\{v_n\}, \quad (33)$$

kde  $E_N$  označuje vnitřní energii kontury,  $E_I$  je obrazová energie a  $E_T$  označuje energii omezení. [26]

Energetická mapa na obrázku zobrazuje data v poli, který využívá celou škálu barev v mapě barev. Mapa barev definuje barvu grafických objektů. Každý prvek v poli určuje barvu pro jeden pixel v obrázku. Výsledný obrázek tvoří  $m \times n$  pixelů, kde  $m$  je počet řádků a  $n$  je počet sloupců v poli. Tyto řádkové a sloupcové indexy prvků určují středy příslušných pixelů. Trojice barev RGB určují intenzitu těchto složek na obrázku. Intenzity jsou obvykle v rozsahu  $[0,1]$ . Hodnota 0 označuje žádnou barvu a hodnota 1 označuje plnou intenzitu. [46]

### 5.3.1.1 Parametry aktivních kontur

V modelu aktivních kontur jsou lokální intenzity obrazu popsány pomocí Gaussova rozdělení s různými průměry a rozptyly. Nejprve musí být vymezena lokální energie s využitím funkce jádra. S vymezenou lokální energií je popsána shoda lokálního Gaussova rozdělení s obrazovými daty v blízkosti bodu. Lokální energie je integrována do celé obrazové oblasti, kde vytváří dvojnásobnou integrální energii, neboli energii lokální Gaussovy distribuční funkce (LGDF). Střední hodnoty a rozptyly lokální intenzity, které jsou prostorově proměnnými funkcemi, jsou dvěma proměnnými funkcemi energie LGDF. Ve výsledném rozvoji křivky se údaje o lokální intenzitě používají k výpočtu hodnot střední hodnoty a rozptylu. Tímto je řízen pohyb křivky až k hranicím objektu.

Vzhledem k definici energie LGDF jako dvojitého integrálu je prvním integrálem vymezena funkce jádra, která charakterizuje přizpůsobení lokálního Gaussova rozdělení lokálním obrazovým datům v okolí bodu; tato lokální energie je pak integrována, aby tvořila datový člen jako dvojitý integrál. Lokální střední hodnoty a rozptyly intenzity jsou dvě proměnné navrhovaného energetického činitele.

Dvojitý integrální energetický činitel je definován takto:

$$E^{LGDF} = \int \Omega E_x^{LGDF} dx = \int \Omega \left( \sum_{i=1}^N \int \Omega_i - \omega(x-y) \log p_{i,x}(I(y)) dy \right) dx \quad (34)$$

$p_{i,x}(I(y))$  je hustota pravděpodobnosti v oblasti  $\Omega_i$ ,  $\omega(x-y)$  je váhovou funkcí,  $\Omega$  je obrazová oblast, funkce logaritmu představuje přechod od maximalizace k minimalizaci energie s využitím činitele  $E_x^{LGDF}$  pro všechny body  $x$  obrazové oblasti  $\Omega$ .

Vychází se z předpokladu, že je obrazová oblast rozdělena na 2 oblasti – popředí  $\Omega_1$  a pozadí  $\Omega_2$ . Tyto dvě oblasti lze reprezentovat jako oblasti vně a uvnitř množiny nulových úrovní  $\varphi$ , kdy

$$\Omega_1 = \{\varphi > 0\} \quad (35)$$

$$\Omega_2 = \{\varphi < 0\} \quad (36)$$

S využitím Heavisidovy funkce  $H$ , je energie  $E^{LGDF}$  lze energii vyjádřit v parametrech  $\varphi, u_i$  a  $\sigma_i^2$ .

$$\begin{aligned} E^{LGDF}(\varphi, u_1(x), u_2(x), \sigma_1(x)^2, \sigma_2(x)^2) = \\ = - \int \omega(x-y) \log p_{1,x}(I(y)) M_1(\varphi(y)) dy - \int \omega(x-y) \log p_{2,x}(I(y)) M_2(\varphi(y)) dy \end{aligned} \quad (37)$$

kde  $M_1(\varphi(y)) = H(\varphi(y))$  a  $M_2(\varphi(y)) = 1 - H(\varphi(y))$ . Proto lze energii  $E^{LGDF}$  přepsat:

$$E^{LGDF}(\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) = \int \Omega E_x^{LGDF}(\varphi, u_1(x), u_2(x), \sigma_1(x)^2, \sigma_2(x)^2) dx \quad (38)$$

Pro přesnější výpočet, který zahrnuje funkci množiny úrovní je potřeba regulovat její odchýlení od funkce pomocí znaménka a je popsána energetickým činitelem:

$$P(\varphi) = \int \frac{1}{2} (|\nabla\varphi(x)| - 1)^2 dx \quad (39)$$

Dále je nutno regulovat nulovou množinu vymezením délky funkce:

$$L(\varphi) = \int |\nabla H(\varphi(x))| dx \quad (40)$$

Celkový energetický činitel je pak:

$$F = (\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) = E^{LGDF}(\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) + \nu L(\varphi) + \mu P(\varphi) \quad (41)$$

kdy  $\nu, \mu > 0$  jsou váhové konstanty. Heavidisova funkce se pak aproximuje vyhlazovací funkcí:

$$H_\varepsilon(x) = \frac{1}{2} \left[ 1 + \frac{2}{\pi} \arctan\left(\frac{x}{\varepsilon}\right) \right] \quad (42)$$

Derivací  $H_\varepsilon$  je vyhlazovací funkce:

$$\delta_\varepsilon(x) = H'_\varepsilon(x) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + x^2} \quad (43)$$

Energetický činitel  $F = (\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2)$  z rovnice (41) se dále aproximuje:

$$F_\varepsilon = (\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) = E_\varepsilon^{LGDF}(\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) + \nu L_\varepsilon(\varphi) + \mu P(\varphi) \quad (44)$$

Minimalizace energetického činitele z rovnice (44) s ohledem na  $\varphi$  lze dosáhnout řešením rovnice toku s klesajícím gradientem:

$$\frac{\partial \varphi}{\partial t} = -\delta_\varepsilon(\varphi)(e_1 - e_2) + \nu \delta_\varepsilon(\varphi) \operatorname{div} \left( \frac{\nabla \varphi}{|\nabla \varphi|} \right) + \mu \left( \nabla^2 \varphi - \operatorname{div} \left( \frac{\nabla \varphi}{|\nabla \varphi|} \right) \right) \quad (45)$$

kde:

$$e_1(x) = \int \Omega \omega(y - x) \left[ \log(\sigma_1(y)) + \frac{(u_1(y) - I(x))^2}{2\sigma_1(y)^2} \right] dy \quad (46)$$


$$e_2(x) = \int \Omega \omega(y - x) \left[ \log(\sigma_2(y)) + \frac{(u_2(y) - I(x))^2}{2\sigma_2(y)^2} \right] dy \quad (47)$$

Aby byla segmentace co nejpřesnější, musí být nastaveny následující parametry:

- **$n$  (NumIter)** – Odhad počtu iteračních kroků, které počítají přiblížení k hranicím objektů.
- **$\Delta t$  (timestep)** – Časový krok, který ovlivňuje rychlost křivky. Čím menší časový krok je, tím je vývoj křivky pomalejší, ale přesnější.
- **$\mu$  (mu)** – Konstanta, která zajišťuje výsledný vývoj křivky. Vede směr křivky až k hranicím objektu a redukuje jeho odchylku
- **$\sigma$  (sigma)** – Je konstanta, která řídí velikost lokální oblasti u Kernelovy funkce. Čím je sigma větší, tím více se křivka posouvá od aktuálního umístění iteračního kroku.
- **$\varepsilon$  (epsilon)** – Šířka Diracova impulsu, která zajistí zrychlený pohyb výchozí inicializační křivky. Čím je hodnota nižší, tím se zformuje přesněji kontura.
- **$c_0$  ( $c_0$ )** – konstantní hodnota, při které jsou vynásobeny hodnoty pixelů uvnitř kontury. Nabývá záporné konstantní hodnoty uvnitř oblasti a kladné konstantní hodnoty mimo oblast.
- **$\lambda_1$  (lambda1)** – Váhová kladná konstanta, kdy je funkce  $e_1(x)$  násobená. Váha je dávana oblasti uvnitř kontury.
- **$\lambda_2$  (lambda2)** – Váhová kladná konstanta, kdy je funkce  $e_2(x)$  násobená. Váha je dávana oblasti mimo konturu.
- **$\nu$  (nu)** – Délková konstanta, při které nižší délka vytvoří větší délku při deformaci kontury.
- **$\alpha$  (alf)** - Váhová konstanta, která se snaží křivku co nejvíce přiblížit ke hraně objektu. [47]

#### 5.3.1.2 Definice inicializační kružnice


Jelikož je převážně většina optických disků kruhovitěho tvaru, je inicializační křivka nadefinovaná jako inicializační kružnice. Kružnice je vždy situována pomocí kurzoru doprostřed objektu zájmu. Po inicializaci dojde k tvarování kružnice tak, že se začne postupně rozevírat až ke hranicím objektu zájmu, vždy po nastavení iteračních kroků. Inicializační kružnice mění svůj tvar tak, že ve výsledku není přesně kruhovitá jako na počátku, ale je postupně deformovaná podle hranice objektu. Proto se spíše této kružnici říká iterační křivka. Pokud by křivka nedosáhla nebo přesáhla hranice objektu, musely by se parametry kružnice nebo iteračních kroků pozměnit.




Obrázek 42. Inicializace a s iteračním krokem 50, 100, 150 a 200

### 5.3.2 Binarizace obrazu


Pro vytvoření binárního snímku musí být nejprve snímek převeden do 2D matice a poté do šedotónového. Až pak následuje převedení na binární snímek. Všechny pixely ze vstupního obrazu s jasem o větší úrovni nahradí hodnota logická 1, neboli bílá barva. U snímku sítnice se jedná o vnitřní oblast optického disku. Všechny ostatní pixely nahradí hodnota logická 0 neboli černá barva. U snímku sítnice se jedná o vnější oblast, tedy oblast mimo optický disk. [48]




Obrázek 43. Ukázka binarizace pro databázi Clarity RetCam3




Obrázek 45. Ukázka binarizace pro databázi Envision RetCam3



Obrázek 44. Ukázka binarizace u databáze Drive



Obrázek 46. Ukázka binarizace pro databázi Phoenix ICON



*Obrázek 47. Ukázka binarizace pro databázi Stare*

## 6 Testování efektivity a evaluace robustnosti detekce pro variabilní obrazová data

### 6.1 Analýza podobnosti modelu optického disku


Zpracované snímky pomocí metody manuální anotace a snímky zpracované metodou automatické segmentace mohly být dále použity pro další studium. Snímky bylo potřeba vzít a porovnat je mezi sebou. Za využití algoritmu *imshowpair* došlo k fúzování snímků přes sebe. Výsledná rozdílnost mezi snímky byla barevně rozlišena. Na snímcích je rozdílnost patrná s využitím purpurové a zelené barvy. Ukázka z jednotlivých rozdílností pro různé modality je na následujících obrázcích:



Obrázek 48. Fúze u databáze Clarity RetCam3



Obrázek 49. Fúze u databáze Drive




Obrázek 50. Fúze u databáze Envision RetCam3





Obrázek 51. Fúze u databáze Phoenix ICON



Obrázek 52. Fúze u databáze Stare

## 6.2 Evaluační parametry po vyhodnocení výkonu segmentace

Pro vyhodnocení kvality zpracovaných snímků metodou manuální anotace a automatické segmentace se využívá evaluačních parametrů. U výpočtů se musí posoudit následující faktory:

- **TP (true positive)** – Pravdivě pozitivní výsledky jsou takové, ve kterých se pixely ve vyšetřovaném objektu považují za pixely, které se v něm skutečně nacházejí.
- **FP (false positive)** – Falešně pozitivní pixely jsou považovány za pixely, které segmentace vyhodnocuje jako součást objektu. Ve skutečnosti součástí objektu nejsou.
- **TN (true negative)** – Pravdivě negativní pixely jsou pixely mimo objekt, které segmentace zařadila mimo objekt.
- **FN (false negative)** – Falešně negativní pixely, které jsou segmentací určeny, že se nacházejí mimo objekt, i když jsou to pixely objektu. [49]

U porovnaných snímků se vypočítaly kvality dílčích metod zpracování. Byly spočítány následující evaluační parametry:

- **Korelační koeficient pro binární masky a pro intenzity OD** - Je míra lineární závislosti dvou náhodných veličin. V matlabu se pro vypočítání využívá funkce *corrcoef*. Jeho rozsah je v rozmezí [0,1]. Čím více se hodnota blíží 1, tím kvalitnější je výsledek.

- **Index strukturální podobnosti pro binární masky a pro intenzity OD** – Je to parametr, který hodnotí 3 faktory u snímku: jas, kontrast a struktura. V MATLABu se implementuje s použitím funkce *ssim*. Jeho rozsah je v rozmezí [0,1]. Menší hodnoty odpovídají horší kvalitě.
- **Střední kvadratická chyba pro binární masky a pro intenzity OD** – V MATLABu se využívá pro vypočítání funkce *imse*. Čím je hodnota chyby menší, tím jsou si obrazy více podobnější.
- **Přesnost** – Je vyjádřením, jak blízko se měření blíží své skutečné hodnotě. Přesnost je dána vztahem:

$$Accuracy = \frac{(TP+TN)}{(FN+FP+TP+TN)} \quad (48)$$

- **Senzitivita** – Měří, jak je citlivý signál na rušení. Senzitivita je dána vztahem:

$$Sensitivity = \frac{TP}{(TP+FP)} \quad (49)$$

- **F-míra** – Je mírou přesnosti zaostření. Je relativním stupněm zaostření obrazu. Jako ideální hodnota Fmíry je považována hodnota rovna 1. Vztah je dán:

$$Fmeasure = \frac{2 \cdot TP}{(2 \cdot TP + FP + FN)} \quad (50)$$

- **Preciznost** – Preciznost identifikuje správně zařazené pozitivní výsledky, mezi všemi pozitivními výsledky. Preciznost je dána vztahem:

$$Precision = \frac{TP}{(TP+FP)} \quad (51)$$

- **Koeficient podobnosti Dice** – Jeho hodnoty jsou ve formě číselného skaláru nebo číselného vektoru s rozsahem [0,1]. Pokud by byla hodnota rovna 1, pak se segmentace na obou snímcích dokonale shoduje. Definice vztahu:

$$Dice = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (52)$$

- **Koeficient podobnosti Jaccard** – Vychází z indexu podobnosti Dice. Jeho hodnoty jsou ve formě číselného skaláru nebo číselného vektoru s rozsahem [0,1]. Pokud by byla hodnota rovna 1, pak se segmentace na obou snímcích dokonale shoduje. Definice vztahu:

$$Jaccard = \frac{Dice}{(2 - Dice)} \quad (53)$$

- **Specificita** – Je počtem správně identifikovaných výsledků mezi všemi negativními výsledky. Specificita je dána vztahem:

$$Specitivity = \frac{TN}{(TN+FP)} \quad (54)$$

Výsledky evaluačních parametrů se vyjadřují v procentech. [50]

### 6.3 Evaluace robustnosti analyzovaných metod


Na základě analýzy podobnosti metod pro segmentaci optického disku byly vypočítány evaluační parametry. Výsledky ze všech zpracovaných snímků ze všech datasetů byly zprůměrovány. Pro větší přehlednost byly průměry z různých evaluačních parametrů pro různé datasety uvedeny v následujících tabulkách. Všechny průměry byly uvedeny v procentech, vyjma střední kvadratické chyby, která se v procentech neuvádí. U některých parametrů byly vypočítány dvakrát a to ve dvou modifikacích. Jedná se o výpočet evaluačního parametru pro binární masky a pro intenzity optického disku. Výpočet binární masky porovnává odhadované binární masky s referenční maskou. Jedná se tedy o srovnání zlatého standardu a segmentace. Výpočty pro intenzity optického disku porovnává odhadovanou intenzitu s referenční intenzitou, tudíž zlatý standard a segmentaci.

Tabulka 2. Průměrné hodnoty evaluačních parametrů

<b>Datasety</b>	<b>Korelační koeficient pro binární masky (%)</b>	<b>Korelační koeficient pro intenzity (%)</b>	<b>Podobnost pro binární masky (%)</b>	<b>Podobnost pro intenzity (%)</b>	<b>Střední kvadratická chyba pro binární masky</b>	<b>Střední kvadratická chyba pro intenzity</b>
<b>Clarity RetCam3</b>	89,554	91,147	99,501	99,444	0,001	12,050
<b>Data Drive</b>	92,272	93,836	98,998	98,905	0,003	73,569
<b>Envision RetCam3</b>	86,491	86,473	99,675	99,641	0,001	19,462
<b>Phoenix ICON</b>	86,292	87,868	99,628	99,589	0,002	35,789
<b>Data Stare</b>	91,505	93,009	98,912	98,807	0,004	67,262


Tabulka 3. Průměrné hodnoty evaluačních parametrů

Dataseť	Přesnost (%)	Senzitivita (%)	F-míra (%)	Preciznost (%)	Koeficient podobnosti Dice (%)	Koeficient podobnosti Jaccard (%)	Specifita (%)
Clarity RetCam3	99,873	90,723	89,429	88,881	89,429	81,042	99,926
Data Drive	99,669	92,863	92,375	92,159	92,375	85,907	99,842
Envision RetCam3	99,853	82,303	86,109	91,724	86,109	75,810	99,957
Phoenix ICON	99,828	82,931	85,760	91,074	85,760	75,556	99,949
Data Stare	99,609	92,802	91,593	90,818	91,593	84,615	99,783




Obrázek 53. Graf porovnaných průměrných hodnot u výsledků korelačního koeficientu pro binární masky

Korelační koeficient pro binární masky viz. obr. 53 ukazoval, že nejlepších výsledků dosahovaly dataseť dospělých lidí. Jednalo se tedy o databáze Drive a Stare. Databáze Drive nabývala nejlepšího výsledku míry korelace a to 92,272 %. Nejhůře dopadla se skoro šestiprocentním rozdílem databáze Phoenix ICON s mírou korelace 86,292 %




Obrázek 54. Graf porovnaných průměrných výsledků korelačního koeficientu pro intenzity OD

Korelační koeficient pro intenzity OD podle obr. 54 vycházel opět nejlépe pro databázi Drive s mírou korelace 93,836 %. Nejhůře pro databázi Envision RetCam 3 s mírou korelace 86,473 %.




Obrázek 55. Graf porovnaných průměrných hodnot u výsledků indexu strukturální podobnosti pro binární masky

Index strukturální podobnosti pro binární masky dosahoval velice příznivých výsledků u všech datasetů. Nejlépe tentokrát dopadla databáze Envision RetCam 3, kde míra kvality obrazu byla 99,675 %. Nejhůře vyšla databáze Stare ani ne s jednocentním rozdílem a to 98,912 % viz obr. 55.




Obrázek 56. Graf porovnaných průměrných hodnot u výsledků indexu strukturalní podobnosti pro intenzity OD

Index strukturální podobnosti pro intenzity OD viz obr. 56 vycházel podobně jako index strukturální podobnosti pro binární masky. Nejlépe vycházela databáze Envision RetCam 3 s mírou kvality obrazu 99,641 %. Nejhůře dopadla databáze Stare opět s malým rozdílem míry kvality obrazu 98,807 %.




Obrázek 57. Graf porovnaných průměrných hodnot u výsledků Střední kvadratické chyby pro binární masky

Vyhodnocení střední kvadratické chyby pro binární masky obr. 57 se posuzovalo opačně. Čím nižší byla hodnota, tím lepší byl výsledek. Nejlépe dopadla databáze Clarity RetCam 3 s hodnotou kolem 0,001. Nejhůře databáze Stare s hodnotou střední kvadratické chyby okolo 0,004.




Obrázek 58. Graf porovnaných průměrných hodnot u výsledků střední kvadratické chyby pro intenzity OD

Střední kvadratická chyba pro intenzity OD ukazovala rozdílnost intenzit pixelů v obou posuzovaných snímcích. Nejlépe dopadla hodnota databáze Clarity RetCam 3, která byla rovna 12,050. Nejhorší dopadla databáze Drive s hodnotou střední kvadratické chyby 73,679.




Obrázek 59. Graf porovnaných průměrných hodnot u výsledků přesnosti

Úspěšnost klasifikace u přesnosti viz. obr. 59 dosahovala vynikajících výsledků pro všechny databáze. Nejlépe pro databázi Clarity RetCam 3 s úspěšností 99,873 %. Nejhorší s rozdílem pár desetin dopadla databáze Stare s úspěšností 99,609 %.



Obrázek 60. Graf porovnaných průměrných hodnot u výsledků senzitivity


Senzitivita viz obr. 60 dopadla nejlépe pro databázi Drive s úspěšností 92,863 %. Nejhorší dopadla databáze Envision RetCam 3 s úspěšností 82,303 %.



Obrázek 61. Graf porovnaných průměrných hodnot u výsledků F-míry


F-míra viz. obr. 61 dopadla nejlépe pro databázi Drive se stupněm přesnosti 92,375 %. Nejhorší stupně přesnosti dopadly pro databázi Phoenix ICON a to 85,760 %.






Obrázek 62. Graf porovnaných průměrných hodnot u výsledků preciznosti

Preciznost obr. 62 byla nejlepší pro databázi Drive s hodnotou 92,159 %. Nejhůře dopadla databáze Clarity RetCam 3 s hodnotou 88,881 %.



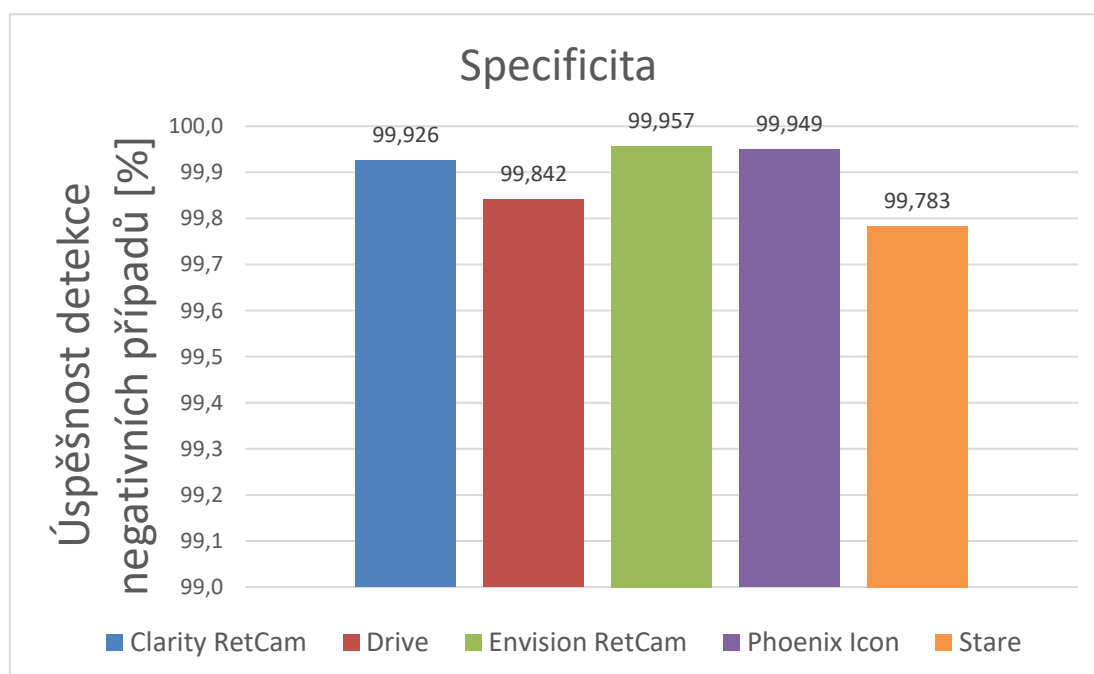
Obrázek 63. Graf porovnaných průměrných hodnot u výsledků koeficientu Dice

Koeficient podobnosti Dice podle obr. 63 vycházel nejlépe pro databázi Drive s mírou přesnosti segmentace 92,375 %. Nejhůře dopadla databáze Phoenix ICON s mírou přesnosti 85,760 %.



Obrázek 64. Graf porovnaných průměrných hodnot u výsledků koeficientu podobnosti Jaccard

Koeficient podobnosti Jaccard viz. obr. 64 dopadl nejlépe pro databázi Drive s mírou podobnosti segmentace 85,907 %. Nejhůře s desetiprocentním rozdílem dopadla databáze Phoenix Icon s mírou podobnosti 75,556 %.

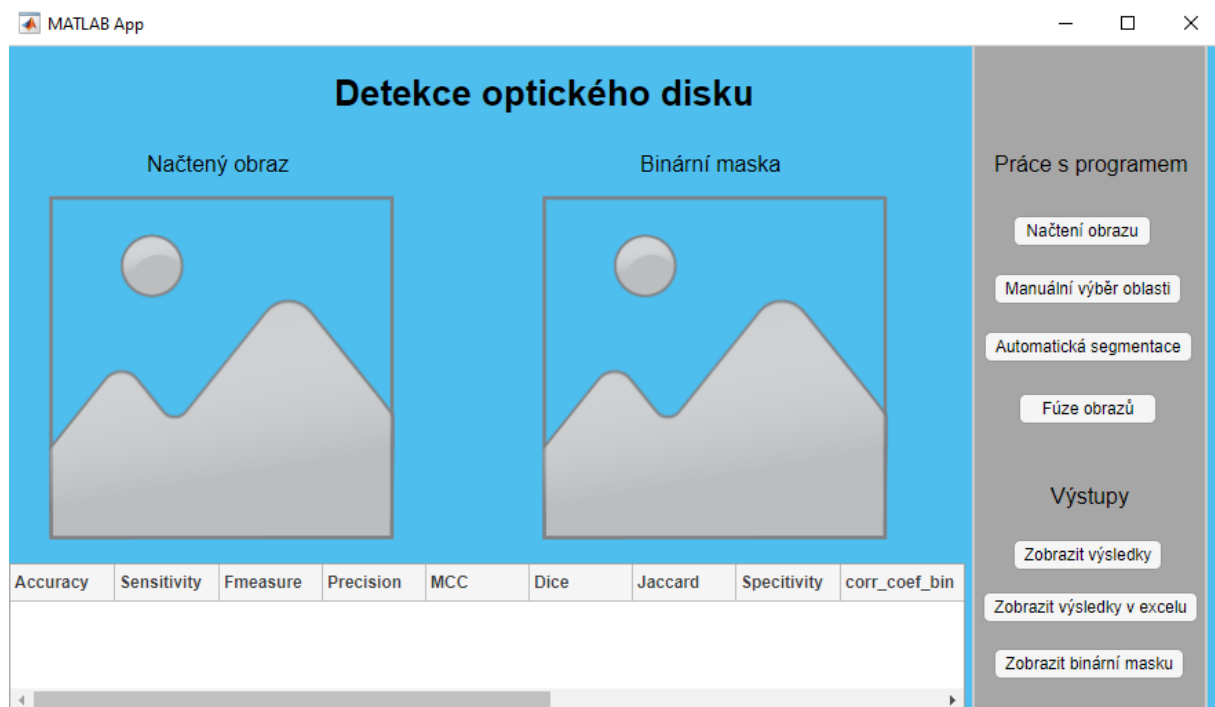


Obrázek 65. Graf porovnaných průměrných hodnot u výsledků specifity

U specifity podle obr. 65 byla nejlépe detekována úspěšnost negativních případů pro databázi Envision RetCam 3 s výsledkem 99,957 %. Nejhůře dopadla úspěšnost detekce pro databázi Stare s výsledkem 99,783 %.

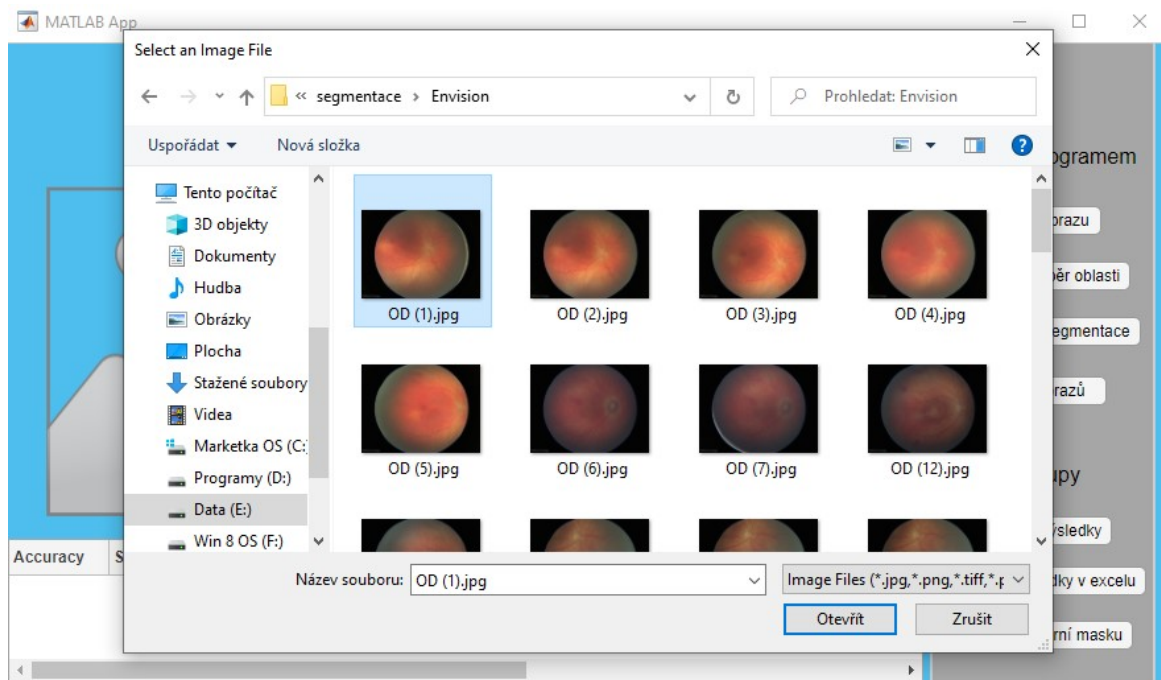
## 7. Návrh softwarového rozhraní

V předešlých kapitolách je vysvětlen segmentační postup a vyhodnocena efektivita metod. Tato kapitola slouží pro popis softwarového prostředí, které mělo automaticky detekovat optický disk. Grafické uživatelské prostředí bylo vytvořeno v programu MATLAB. Cílem bylo vytvořit pro uživatele co nejjednodušší ovládání tak, aby uživatel mohl jednoduše zakliknout optický disk.




Obrázek 66. Návrh softwarového prostředí

Pro spuštění programu musí mít uživatel práva pro zápis na disk. Po spuštění aplikace se zobrazilo okno pro detekci optického disku, u kterého bylo potřeba nejprve načíst obrázek pomocí tlačítka „Načtení obrázku“, viz. obr. 67.



Obrázek 67. Načtení obrázku

Nejprve se zakliklo tlačítko „Manuální výběr oblasti“ viz. obr. 68, u kterého bylo možné ohraničit ručně optický disk držením levého tlačítka myši a tažením. Po vybrání oblasti zájmu se udělal dvojklik levým tlačítkem myši do oblasti zájmu. Výsledek se mohl načíst pomocí tlačítka „Zobrazit binární masku“, viz. obr. 69.

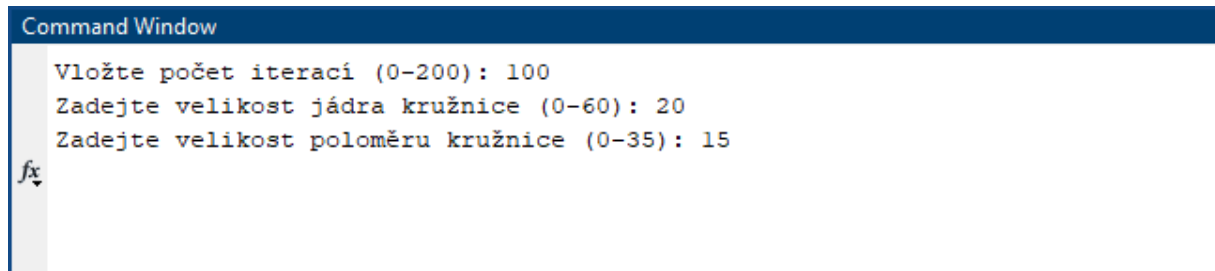


Obrázek 68. Manuální označení



Obrázek 69. Binární maska - výsledek manuálního označení

Po zakliknutí tlačítka „Automatická segmentace“ došlo k inicializaci optického disku, u které se navolily libovolné velikosti parametrů viz. obr. 70. Opět se mohl načíst binární obraz pomocí tlačítka „Zobrazit binární masku“. Načítání binárního obrazu mohlo u některých snímků trvat delší dobu.



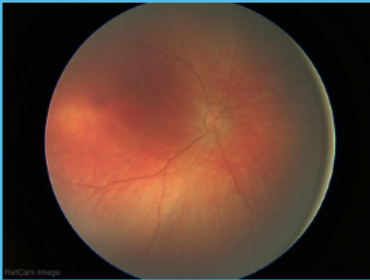
Obrázek 70. Zvolení velikostí parametrů

Nakonec bylo zvoleno tlačítko „Fúze obrazů“, u kterého došlo k překrytí obou snímků. Hodnoty evaluačních parametrů se vypsaly v tabulce pod obrázky po zvolení tlačítka „Zobrazit výsledky“, viz. obr. 71. Výsledky evaluačních parametrů bylo také možné otevřít v programu Microsoft Excel pomocí tlačítka „Zobrazit výsledky v Excelu“.

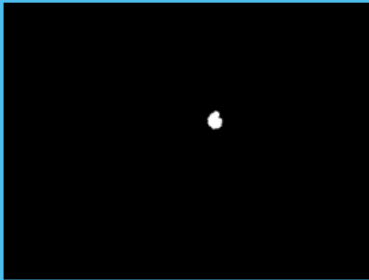
MATLAB App

## Detekce optického disku

Načtený obraz



Binární maska



Accuracy	Sensitivity	Fmeasure	Precision	MCC	Dice	Jaccard	Specitivity	corr_coef_bin
0.9986	0.5678	0.7230	0.9948	0.7510	0.7230	0.5661	1.0000	0.7510

Práce s programem

Načtení obrazu

Manuální výběr oblasti

Automatická segmentace

Fúze obrazů

Výstupy

Zobrazit výsledky

Zobrazit výsledky v excelu

Zobrazit binární masku

Obrázek 71. Výsledný překrytý obraz s evaluačními parametry

## 8. Diskuse a objektivní vyhodnocení výsledků

Pro testování výsledků segmentace byly vybrány snímky zachycené fundus kamerou. Fundus kamera zachytila sítnice dospělých. Druhá sada snímků byla tvořena digitálním zobrazovacím systémem Retcam a Phoenix ICON, který slouží k fotodokumentaci sítnice převážně novorozenců, ať už donošených, nebo předčasně narozených. Celkově se vyhodnotilo 13 evaluačních parametrů pro porovnání segmentačních metod optického disku.

Nedílnou součástí segmentace obrazu je jeho kvalitní zpracování a tedy i jeho předzpracování. Jednotlivé korekce obrazu, ať už je to ekvalizace histogramu nebo filtrace ovlivní, jak moc bude viditelná oblast zájmu. Předzpracování je tedy potřebné. Nemůže se vycházet z čistě nativního snímku, protože by mohlo dojít ke znehodnocení obrazu a k výskytu různých artefaktů v obraze. Obraz se lépe zpracovává, pokud je jeho hodnota pixelů snížena.

Jediným evaluačním parametrem, který není uvedený v procentech, je střední kvadratická chyba pro binární masky a střední kvadratická chyba pro intenzity optického disku. Pokud je u evaluačních parametrů výsledek roven 1, znamená to perfektní segmentaci, zatímco hodnota 0 znamená nejhorší nebo také zcela odlišné výsledky. Po převedení na procenta lze říct, že 100 % znamená nejlepší výsledek nebo také dokonale shodující se výsledek. U střední kvadratické chyby je tomu naopak. Čím jsou si obrazy podobnější, tím je velikost kvadratické chyby menší. Výsledky jsou také znázorněny ve sloupcových grafech.

Korelační koeficient pro binární masky vyhodnotil jako neúspěšnější míru korelace u databáze Drive 92,272 %. Databáze Stare si také vedla úspěšně. Hůře na tom byly výsledky RetCamu a Phoenix ICON, který dopadl nejhůře s 86,292 %. Korelační koeficient pro intenzity optického disku dosahoval podobných výsledků. Opět nejlépe dopadla míra korelace u databáze Drive s 93,836 %. Databáze Stare byla srovnatelná s databází Drive. Nejhůře dopadlo Envision RetCam 3 s hodnotou 86,473 %.

Index strukturální podobnosti pro binární masky vyhodnotil jako nejlepší míru kvality obrazu u databáze Envision RetCam 3 s 99,675 %. Výsledky všech datasetů si byly velice podobné a nebyl v nich razantní rozdíl. Nejhůře dopadly výsledky z databáze Stare 98,912 %, u které byl rozdíl od nejlepší databáze necelé jedno procento. Index strukturální podobnosti pro intenzity OD byl prakticky totožný jako index strukturální podobnosti pro binární masky. Nejlepší míry kvality obrazu dosáhla databáze Envision RetCam3 s výsledkem 99,641 % a nejhůře databáze Stare 98,807 %. Opět byl rozdíl minimální.

U střední kvadratické chyby pro binární masky a intenzity OD znamenala nižší hodnota lepší výsledek. Vypočítává se jako průměr rozdílů odhadované binární masky nebo intenzity od referenční binární masky nebo intenzity. Pokud byla hodnota rovna 0, odhadovaná binární maska od referenční binární masky se dokonale shodovala. Pokud byla odhadovaná intenzita rovna 0, tak odhadovaná intenzita a referenční intenzita se dokonale shodovaly. U střední kvadratické chyby pro binární masky nejlepších hodnot dosáhla databáze Clarity RetCam 3 s hodnotou 0,001. Nejhůře dopadla databáze Stare s hodnotou 0,004. Hodnoty se výrazně blížily k 0, což znamenalo téměř shodující se výsledky s referenční binární maskou. U střední kvadratické chyby pro intenzity OD byl výraznější rozdíl. Nejlépe dopadla databáze Clarity RetCam 3 s hodnotou 12,050. Nejhůře dopadla databáze Drive s hodnotou 73,569. U intenzity hraje určitou roli, kolik světlého místa bylo na snímků zaznamenáno. Vyšší hodnota znamenala světlejší pixely. Databáze Drive dosahovala výraznějších světlejších míst z důvodů téměř shodného překrytí obrazů.

Přesnost (Accuracy) každého datasetu se lišila pouze v desetínách procent. Nejúspěšněji byla klasifikována databáze Clarity RetCam 3 99,873 %. Nejhůře byla klasifikována databáze Stare 99,609 %. U senzitivity byl rozdíl mezi datasey větší. Nejlépe byla vyhodnocena databáze Drive s 92,863 %, nejhůře databáze Envision RetCam 3 s 82,303 %. Specificita dosahovala také téměř dokonalých shod. Nejlépe dopadla databáze Envision RetCam 3 s 99,957 %. Nejhůře dopadla databáze Stare s hodnotou 99,783 %. Rozdíl byl opět pouze v desetínách procent.

F-míra vyhodnotila jako největší shodu databázi Drive 92,375 %. Nejhůře databázi Phoenix ICON 85,760 %. U preciznosti nejlépe vycházela databáze Drive 92,159 %, ale nejhůře Clarity RetCam 3 s hodnotou 88,881 %. Koeficient podobnosti Dice vyhodnotil nejpřesnější shodu u databáze Drive 92,375 %. Nejméně se shodovaly snímky z databáze Phoenix ICON 85,760 %. Koeficient podobnosti Jaccard vyhodnotil největší shodu u databáze Drive 85,907 %. Nejmenší shoda byla u databáze Phoenix ICON 75,556 %.

Ze všech posuzovaných evaluačních parametrů mohlo dojít k vyhodnocení. Jako nejúspěšnější testování snímků bylo vyhodnoceno u databáze Drive. Nejhorších výsledků dosahovala databáze Stare. Určitou roli mohla hrát kvalita zpracovávaných snímků. Navíc spoustu snímků optických disků z databáze Stare mělo atypický tvar. Jednalo se o snímky, na kterých bylo výraznější onemocnění zrakového nervu a tím byl optický disk hůře detekovatelný.

Snímky pořízené ve FNO dosahovaly celkově horších výsledků než databáze Drive. V tomto případě hrálo roli, že byly snímky opakovaně pořízeny u stejného pacienta. Větším problémem by mohla být vzdálenost optického disku, tzn. optický disk byl značně menší než snímky z databáze Drive a Stare. Celkovým problémem u snímků z FNO bylo menší rozlišení, které má za následek horší obrazové vlastnosti optického disku a poté taky horší výsledky segmentace. Také horší výsledky mohla způsobit nespolečná novorozence.



## Závěr

Cílem této diplomové práce bylo srovnání zobrazovacích modalit pro segmentaci optického disku a následné evaluační vyhodnocení robustnosti těchto metod analýzy. Jednalo se o větší testování a porovnání automatizovaných metod segmentace obrazu pro detekci optického disku.

Pro realizaci bylo potřeba se v první části diplomové práce seznámit s přístroji, s kterými se vyšetřuje a diagnostikuje oční pozadí. Jednalo se o metody přímé a nepřímé oftalmoskopie. Jsou to metody vyšetření, které jsou denní praxí každého očního vyšetření. Vývoj těchto metod jde stále kupředu a čím dál, tím více se tyto vyšetření zkvalitňují a zdokonalují. Druhou částí byl popis samotného procesu segmentace. Konkrétně byl popis zaměřený na segmentaci založené na regionech. Bylo to z toho důvodu, že právě v reálných patientských datech byl hledán region, neboli oblast zájmu.

Při návrhu a testování algoritmu bylo k dispozici 232 snímků z různých databází. Jednalo se o reálná patientská data dospělých pacientů a nedonošených dětí. Některé datasey byly volně dostupné na internetu a druhou sadu dat poskytl Oční oddělení Fakultní nemocnice Ostrava. Každý snímek musel být individuálně zpracovaný. Při manuálním zpracování byl na snímku vytyčen tzv. zlatý standard, neboli obrázek převedený na binární obraz. Postup automatické segmentace zahrnoval několik technik předzpracování, kde nejdůležitějšími metodami byla metoda CLAHE a Bilaterální filtr. Samotný algoritmus segmentace byl založen na metodě aktivních kontur bez hran. Tento algoritmus byl závislý na vstupních parametrech. Správné zvolení parametrů náležitě ohraničilo optický disk. Výsledkem byl binární obraz, kde optický disk byl bílý a měl hodnotu log 1 a černé pozadí mělo hodnotu log 0. Oba obrazy, jak z manuální anotace, tak ze segmentace aktivními konturami bez hran, se fúzovaly. Barevně byly odlišeny rozdíly mezi jednotlivými metodami. Pomocí evaluačních parametrů byla vyhodnocena kvalita výsledné segmentace.

Podle vypočítaných evaluačních parametrů byl stanoven závěr, že lepších výsledků dosahovala patientská data dospělých lidí. Konkrétně se jednalo o databázi Drive. Při vyhodnocení ve velké míře záleželo, jak byly snímky pořízené. Přesvětlení obrazu nebo zhoršená viditelnost optického disku mohla být důsledkem horších výsledků. Celkovou roli také mohl hrát fakt, že patientská data nedonošených dětí byly snímky se značně menšími optickými disky než u dospělých pacientů. U snímků nedonošených dětí navíc byly vícekrát použity snímky z jednoho oka. U některých snímků mělo na výsledné hodnocení negativní vliv atypického optického disku. Proto v některých případech aktivní kontura nemohla dosáhnout úplně přesné hranice optického disku. Toto se často stávalo u databáze Stare. Proto byla databáze často zdokumentována horšími výsledky.

Na závěr bylo vytvořeno grafické uživatelské rozhraní. Rozhraní mělo umožnit uživateli pomocí jednoduchých tlačítek provést úkony, které mu pomohly vybrat oblast zájmu, v tomto případě optický disk. Na základě úkonů došlo k sjednocení metod pro detekci optického disku a ke zhodnocení kvality segmentace pomocí tabulky s evaluačními parametry.

## Seznam literatury

- [1] MORNSTEIN, Vojtěch, Ivo HRAZDIRA a Aleš BOUREK. *Lékařská fyzika a informatika: (se zaměřením na zubní lékařství)*. Brno: Neptun, 2007. ISBN 978-80-86850-02-3
- [2] NOVÁK, Vilém. *Diagnostické metody v medicíně*. Ostrava: VŠB - Technická univerzita Ostrava, 2013. ISBN 978-80-248-3101-5
- [3] Optical coherence tomography: fundamental principles, instrumental designs and biomedical applications. *Biophysical Reviews* [online]. 2011, Sep., 3(3), 155 [cit. 2022-11-10]. Dostupné z: doi:10.1007/s12551-011-0054-7
- [4] [12] DRAHANSKÝ, M., R. KOLÁŘ a T. MŇUK. Elektronické zařízení pro snímání obrazu sítnice a duhovky oka. *Česká a slovenská oftalmologie*. **2015**(6), 6. Dostupné z: doi:https://www.prolekare.cz/casopisy/ceska-slovenska-oftalmologie/2015-6/elektronicke-zarizeni-pro-snimani-obrazu-sitnice-a-duhovky-oka-57173
- [5] Introduction to the Fundoscopic / Ophthalmoscopic Exam [online]. Canada: Stanford University School of Medicine, c2022 [cit. 2022-10-27]. Dostupné z: https://stanfordmedicine25.stanford.edu/the25/fundosopic.html
- [6] KUČHYŇKA, Pavel. *Oční lékařství*. 2., přepracované a doplněné vydání. Praha: Grada Publishing, 2016. ISBN 978-80-247-5079-8
- [7] KOLÍN, Jan. *Oční lékařství*. 2., přeprac. vyd. Praha: Karolinum, 2007. ISBN 978-80-246-1325-3
- [8] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje 1*. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013. ISBN 978-80-248-3107-7
- [9] TIMBERLAKE, George T. a Michael KENNEDY. *The Direct Ophthalmoscope How it Works and How to Use It* [online]. University of Kansas Medical Center, 20005 [cit. 2022-11-18]. Dostupné z: https://web.media.mit.edu/~raskar/Eye/TheDirectOphthalmoscope.pdf. © University of Kansas
- [10] GERLLICH, Marcus - Matthias. In: *The Slit Lamp: Applications for Biomicroscopy and Videography* [online]. 1. Kellinghusen Germany: Springer-Verlag Berlin Heidelberg, 2014, s. 234 [cit. 2022-10-18]. ISBN 978-3-642-39793-6. Dostupné z: 10.1007/978-3-642-39793-6
- [11] Fundus Photography in the 21st Century—A Review of Recent Technological Advances and Their Implications for Worldwide Healthcare. *Telemed JE Health* [online]. 2016, **22**(3), 198–208 [cit. 2022-10-20]. Dostupné z: doi:10.1089/tmj.2015.0068
- [12] SAINE, Patrick J. a Marshall E. TYLER. In: *Ophthalmic Photography: Retinal Photography, Angiography, and Electronic Imaging*. 2. Oxford: Butterworth-Heinemann Medical, November 28, 2001, s. 424. ISBN 0750673729
- [13] HAJIZADEH, Fedra, ed. *Atlas of ocular optical coherence tomography*. Tehran, Iran: Springer International Publishing, c2018. ISBN 978-3-319-66757-7
- [14] ROZSÍVAL, Pavel. *Oční lékařství*. Druhé, přepracované vydání. Praha: Galén, [2017]. ISBN 978-80-7492-316-6

- [15] MATUŠKOVÁ, V., J. LÍZROVÁ PREININGEROVÁ, D. VYSLOUŽILOVÁ, M. MICHALEC, Z. KASL a E. VLKOVÁ. Použití optické koherenční tomografie u roztroušené sklerózy. *Česká a slovenská neurologie a neurochirurgie*. 1/2016n. I., **2016**(1), 8. Dostupné z: doi:<https://www.csnn.eu/casopisy/ceska-slovenska-neurologie/2016-1/pouziti-opticke-koherencni-tomografie-u-roztrousene-sklerozy-57237>
- [16] BILLE, Josef F., ed. *High Resolution Imaging in Microscopy and Ophthalmology: New Frontiers in Biomedical Optics* [online]. 1. Heidelberg, Germany: Springer Cham, 2019 [cit. 2022-10-19]. ISBN 978-3-030-16638-0. Dostupné z: <https://doi.org/10.1007/978-3-030-16638-0>
- [17] HRAZDIRA, Ivo a Vojtěch MORNSTEIN. *Lékařská biofyzika a přístrojová technika*. Brno: Neptun, 2001. ISBN 80-902896-1-4
- [18] QUANTITATIVE TOPOGRAPHIC CURVATURE MAPS OF THE POSTERIOR EYE UTILIZING OPTICAL COHERENCE TOMOGRAPHY. *Retina* [online]. Oftalmologická klinika, Duke University Medical Center, Durham, Severní Karolína;, 01 Apr 2021n. I., **41**(4), 804-811 [cit. 2022-11-10]. Dostupné z: doi:10.1097/iae.0000000000002897
- [19] VAZQUEZ, Luis E. a Linda Y. HUANG. Analýza RNFL v diagnostice glaukomu. *Glaucoma Today* [online]. květen/červen 2016 [cit. 2022-10-20]. Dostupné z: <https://glaucomatoday.com/articles/2016-may-june/rnfl-analysis-in-the-diagnosis-of-glaucoma>
- [20] SKORKOVSKÁ, Karolína. *Význam strukturálních metod při sledování pacientů s oční hypertenzí*. Brno, 2005. Disertační práce. Masarykova Univerzita v Brně, Lékařská fakulta
- [21] CVENKEL, Barbara. Nové zobrazovací metody v časně diagnostice glaukomu. *Zdrav Vestn Supl* [online]. Ljubljana, 2012, 81(I), 157-169 [cit. 2022-10-26]. Dostupné z: [https://www.researchgate.net/publication/287014076\\_Heidelberg\\_Retina\\_Tomograph\\_for\\_the\\_Detection\\_of\\_Glaucoma](https://www.researchgate.net/publication/287014076_Heidelberg_Retina_Tomograph_for_the_Detection_of_Glaucoma)
- [22] BARTOŠ, Dušan. Nové zobrazovací metody v časně diagnostice glaukomu. *Vojenské zdravotnické listy* [online]. Praha, 2003, 72(2), 68-71 [cit. 2022-10-26]. Dostupné z: <https://www.mmsl.cz/pdfs/mms/2003/02/07.pdf>
- [23] Quantitative Three-Dimensional Imaging of the Posterior Segment with the Heidelberg Retina Tomograph [online]. © Heidelberg Engineering GmbH, Heidelberg, Germany, 1-16 [cit. 2022-10-26]. Dostupné z: <http://www.oftech.com.ar/Lecturas/heidelberg.pdf>
- [24] SEMMLOW, John L. a Benjamin GRIFFEL. *Biosignal and medical image processing*. 3rd. Broken Sound Parkway NW: Taylor & Francis Group, c2014. ISBN 978-1-4665-6736-8
- [25] HÁJOVSKÝ, Radovan, Radka PUSTKOVÁ a František KUTÁLEK. *Zpracování obrazu v měřicí a řídicí technice*. Vyd. 1. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2012. [online] [cit. 2022-11-11]. ISBN 978-80-248-2596-0. Dostupné z: <http://www.person.vsb.cz/archivcd/FEI/ZOMRT/Zpracovani%20obrazu%20v%20merici%20a%20ridici%20technice.pdf>
- [26] ŠPANĚL, Michal a Vítězslav BERAN. *Obrazové segmentační techniky: Přehled existujících metod*. Brno, 2005. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA INFORMAČNÍCH TECHNOLOGIÍ ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ
- [27] KASAL, Pavel a Štěpán SVAČINA. *Lékařská informatika*. Praha: Karolinum, 1998. ISBN 80-7184-594-9

- [28] TYAGI, Mrinal. Image Segmentation: Part 1: Mathematical and practical implementation of various image segmentation techniques. *Towards data science* [online]. 2021 [cit. 2022-10-20]. Dostupné z: <https://towardsdatascience.com/image-segmentation-part-1-9f3db1ac1c50>
- [29] A Performance Comparison of Edge Detection Techniques for Printed and Handwritten Document Images. *International Journal of Innovative Research in Computer and Communication Engineering* [online]. May 2016, (5), 1-12 [cit. 2022-10-30]. Dostupné z: [https://www.researchgate.net/publication/339551773\\_A\\_Performance\\_Comparison\\_of\\_Edge\\_Detection\\_Techniques\\_for\\_Printed\\_and\\_Handwritten\\_Document\\_Images](https://www.researchgate.net/publication/339551773_A_Performance_Comparison_of_Edge_Detection_Techniques_for_Printed_and_Handwritten_Document_Images)
- [30] Review of research on the instance segmentation of cell images. *Computer Methods and Programs in Biomedicine* [online]. 2022, **2022**(227), 8 [cit. 2022-11-06]. Dostupné z: <https://reader.elsevier.com/reader/sd/pii/S0169260722005922?token=119C51697BE919B2042E2F1D1535072E7CDCAFOA1A4927E96D399CC86526C09FA81F15F5F424735425F7D8607FD67D3B&originRegion=eu-west-1&originCreation=20221112115205>
- [31] A Review on Region Based Segmentation. *International Journal of Science and Research* [online]. April 2015, **4**(4), 3194-3197 [cit. 2023-01-10]. ISSN 2319-7064. Dostupné z: [https://www.ijsr.net/get\\_abstract.php?paper\\_id=27041504](https://www.ijsr.net/get_abstract.php?paper_id=27041504)
- [32] What Is Image Segmentation?. *MathWorks* [online]. c1994-2022 [cit. 2022-10-29]. Dostupné z: <https://ch.mathworks.com/discovery/image-segmentation.html>
- [33] KALOVÁ, Ilona. *Počítačové vidění* [online]. Brno, 2019 [cit. 2022-11-10]. Dostupné z: [https://repozitar.cz/repo/37495/Bryjova\\_Z\\_M\\_A\\_O\\_D.pdf](https://repozitar.cz/repo/37495/Bryjova_Z_M_A_O_D.pdf). Přednáška. Vysoké učení technické v Brně
- [34] FASIHI, Maedeh Sadat a Wasty B. Mikhael FELLOW. Overview of current Biomedical Image segmentation methods. *International Conference on Computational Science and Computational Intelligence* [online]. Las Vegas, USA, 2016, 2016(1), 1-6 [cit. 2022-11-17]. Dostupné z: doi:10.1109/CSCI.2016.0156
- [35] Optic Disk Detection in Fundus Image Based on Structured Learning. *IEEE Journal of Biomedical and Health Informatics* [online]. 05 July 2017n. l., **22**(1), 224 - 234 [cit. 2022-11-09]. ISSN 2168-2208. Dostupné z: doi:10.1109/JBHI.2017.2723678
- [36] Automatic Segmentation of the Optic Nerve Head Region in Optical Coherence Tomography: A Methodological Review. *Computer Methods and Programs in Biomedicine* [online]. 2022, **2022**(106801), 1-13 [cit. 2022-11-17]. ISSN 01692607. Dostupné z: doi:10.1016/j.cmpb.2022.106801
- [37] Segmentation of the optic disc and optic cup using a machine learning-based biregional contour evolution model for the cup-to-disc ratio. *Multimedia Tools and Applications* [online]. 2022, **81**(25), 36217–36238 [cit. 2022-11-20]. ISSN 13807501. Dostupné z: doi:10.1007/s11042-021-11583-8
- [38] Digital Image Processing. *Learn DIP simply easy learning* [online]. Kavuri Hills, Madhapur, Hyderabad, Telangana, INDIA: Tutorials Point India Private Limited, © Copyright 2023 [cit. 2023-03-30]. Dostupné z: <https://www.tutorialspoint.com/dip/>
- [39] *Color* [online]. The MathWorks, © 1994-2023 [cit. 2023-04-10]. Dostupné z: [https://www.mathworks.com/help/images/color.html?searchHighlight=color&s\\_tid=srchtitle\\_color\\_3](https://www.mathworks.com/help/images/color.html?searchHighlight=color&s_tid=srchtitle_color_3)

- [40] *Contrast Limited Adaptive Histogram Equalization* [online]. The MathWorks, © 1994-2023 [cit. 2023-04-10]. Dostupné z: <https://www.mathworks.com/help/visionhdl/ug/contrast-adaptive-histogram-equalization.html>
- [41] HORÁK, Karel. Jasové transformace. *Computer Vision Group* [online]. Brno: Fakulta elektrotechniky a komunikačních technologií VUT, 2010 [cit. 2023-04-11]. Dostupné z: [http://vision.uamt.feec.vutbr.cz/ZVS/lectures/05\\_Jasove\\_transformace.pdf](http://vision.uamt.feec.vutbr.cz/ZVS/lectures/05_Jasove_transformace.pdf)
- [42] KELLER, Petr. *Bezkontaktní měření rozměrů zpracováním digitálního obrazu*. Liberec, 2003. Doktorská práce. Technická Univerzita v Liberci - Fakulta strojní
- [43] BRYJOVÁ, Iveta. *Zpracování medicínských a obrazových dat* [online]. Opava, 2019 [cit. 2022-11-10]. Dostupné z: [https://repozitar.cz/repo/37495/Bryjova\\_Z\\_M\\_A\\_O\\_D.pdf](https://repozitar.cz/repo/37495/Bryjova_Z_M_A_O_D.pdf). Studijní text pro prezenční formu studia. Slezská Univerzita v Opavě
- [44] B. -H. Chen, Y. -S. Tseng and J. -L. Yin, "Gaussian-Adaptive Bilateral Filter," in *IEEE Signal Processing Letters*, vol. 27, pp. 1670-1674, 2020, doi: 10.1109/LSP.2020.3024990
- [45] Structure-aware adaptive bilateral texture filtering. *Digital Signal Processing* [online]. 2022, (123), 1-13 [cit. 2023-04-18]. Dostupné z: <https://doi.org/10.1016/j.dsp.2022.103386>
- [46] *Colormap* [online]. The MathWorks, © 1994-2023 [cit. 2023-04-18]. Dostupné z: <https://ch.mathworks.com/help/matlab/ref/colormap.html>
- [47] WANG, Li. Active contours driven by local Gaussian distribution fitting energy. *Signal processing* [online]. 2009, 89(12), 2435-2447 [cit. 2023-04-11]. Dostupné z: <https://doi.org/10.1016/j.sigpro.2009.03.014>
- [48] *Imbinarize* [online]. The MathWorks, © 1994-2023 [cit. 2023-04-10]. Dostupné z: <https://www.mathworks.com/help/images/ref/imbinarize.html>
- [49] AZIZ TAHA, Abdel a Allan HANBURY. Metrics for evaluating 3D medical image segmentation: Analysis, selection, and tool. *BMC Medical Imaging* [online]. 2015, 15(29), 1 - 28 [cit. 2023-04-18]. Dostupné z: 10.1186/s12880-015-0068-x
- [50] *Help Center* [online]. The MathWorks, © 1994-2023 [cit. 2023-04-10]. Dostupné z: <https://ch.mathworks.com/help/>

## Seznam příloh

Příloha I. Příloha v IS Edison