

Softwarové prostředí pro klasifikaci a extrakci retinálních lézí z retinálních obrazových dat s využitím prvků umělé inteligence

Software Environment for Classification and Extraction
of Retinal Lesions with using Artificial Intelligence
Methods

Bc. Nikola Vavrečková

Diplomová práce

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

Ostrava, 2022

Zadání

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání diplomové práce

Student: **Bc. Nikola Vavrečková**

Studijní program: N0988A060001 Biomedicínské inženýrství

Téma: Softwarové prostředí pro klasifikaci a extrakci retinálních lézí z retinálních obrazových dat s využitím prvků umělé inteligence
Software Environment for Classification and Extraction of Retinal Lesions with using Artificial Intelligence Methods

Jazyk vypracování: čeština

Zásady pro vypracování:

1. Nastudování základních principů a přístrojové techniky pro zobrazování retinální oblasti.
2. Nastudování principů klasifikace obrazových záznamů s využitím umělé inteligence.
3. Rešerše metod pro detekci a kvantifikaci retinálních lézí.
4. Tvorba datové báze retinálních obrazů u onemocnění ROP.
5. Design a realizace modelu pro klasifikaci retinálních obrazů, obsahující retinální léze.
6. Design a realizace hybridního algoritmu pro identifikaci retinálních lézí.
7. Procedura pro objektivní posouzení manifestace retinálních lézí vůči klinickým standardům.
8. Tvorba softwarového prostředí pro automatizovanou analýzu retinálních lézí u onemocnění ROP.
9. Zhodnocení výsledků práce.

Seznam doporučené odborné literatury:

- [1] DHAWAN, Atam P. Medical image analysis. Hoboken: Wiley, c2003. IEEE Press series on biomedical engineering. ISBN 0-471-45131-2.
- [2] SEMMLOW, John L. a Benjamin GRIFFEL. Biosignal and medical image processing. 3rd ed. Boca Raton: CRC Press, c2014. ISBN 978-1-4665-6736-8.
- [3] COSTA, Luciano da Fontoura a Roberto Marcondes CESAR. Shape analysis and classification: theory and practice. Boca Raton: CRC Press, c2001. Image processing series. ISBN 0-8493-3493-4.
- [4] AGGARWAL, Charu C., ed. Data classification: algorithms and applications. Boca Raton: CRC Press, Taylor & Francis Group, [2015]. Chapman & Hall/CRC data mining and knowledge discovery series. ISBN 978-1-4665-8674-1.

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

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

Datum zadání: 01.09.2021

Datum odevzdání: 30.04.2022

prof. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry

prof. Ing. Jan Platoš, Ph.D.
děkan fakulty

Abstrakt

Cílem této diplomové práce je vytvořit algoritmus v MATLABu a softwarové prostředí pro automatizovanou extrakci retinálních lézí z retinálních obrazových dat s využitím prvků umělé inteligence a následné testování výsledků navrhovaného algoritmu. Úvod práce pojednává o základních principech a přístrojích používaných pro zobrazování retinální oblasti. Nejdůležitější částí této práce je návrh hybridního algoritmu a jeho následné objektivní posouzení. Hybridní algoritmus kombinuje dva segmentační algoritmy a sestává ze tří hlavních částí. V první části je využit algoritmus pro segmentaci retinálních lézí, který však v mnoha případech chybně segmentuje i oblasti cévního řečiště. Z toho důvodu je v druhé části implementován algoritmus pro segmentaci cévního řečiště a oba výsledky segmentačních algoritmů se následně odečtou. Třetí částí hybridního algoritmu je postprocessing založený na extrakci příznaků. Vytvořený algoritmus byl testován na datasetu poskytnutém Oční klinikou Fakultní nemocnice v Ostravě. V závěru je vytvořeno graficko-uživatelské rozhraní v App Designeru.

Klíčová slova

Segmentace, detekce, hybridní algoritmus, retina, retinální léze, umělá inteligence, retinální obrazová data, zobrazovací metody, RetCam3, MATLAB, GUI

Abstract

The aim of this diploma thesis is to create an algorithm in MATLAB and a software environment for automated extraction of retinal lesions from retinal image data using elements of artificial intelligence and subsequent testing of the results of the proposed algorithm. The introduction deals with the basic principles and devices used for imaging the retinal area. The most important part of this work is the design of a hybrid algorithm and its subsequent objective assessment. The hybrid algorithm combines two segmentation algorithms and consists of three main parts. In the first part, an algorithm for segmentation of retinal lesions is used, which, however, in many cases also incorrectly segments areas of the vascular riverbed. For this reason, an algorithm for vascular riverbed segmentation is implemented in the second part, and both results of the segmentation algorithms are subsequently subtracted. The third part of the hybrid algorithm is postprocessing based on feature extraction. The developed algorithm was tested on a dataset provided by the Eye Clinic of the University Hospital in Ostrava. Finally, a graphical user interface in the App Designer is created.

Keywords

Segmentation, detection, hybrid algorithm, retina, retinal lesions, artificial intelligence, retinal image data, imaging methods, RetCam3, MATLAB, GUI

Poděkování

Touto cestou bych ráda poděkovala mému vedoucímu práce panu Ing. Janu Kubíčkoví, Ph.D. za jeho cenné rady, připomínky, odborné konzultace, a především trpělivost během vytváření této diplomové práce. Dále bych chtěla poděkovat Oční klinice Fakultní nemocnice V Ostravě za poskytnutí obrazových dat pro zpracování. Poděkování patří i mé rodině a příteli za jejich podporu a pevné nervy.

Obsah

Seznam použitých symbolů a zkratk	8
Seznam ilustrací	9
Seznam tabulek	12
Úvod	13
1 Základní principy pro zobrazování sítnice	14
1.1 Oftalmoskopie	14
1.1.1 Přímá oftalmoskopie	14
1.1.2 Nepřímá oftalmoskopie	15
1.2 Skenovací laserová oftalmoskopie (SLO)	15
1.3 Heidelberg retinální tomografie	17
1.4 Ultrasonografie	18
1.5 Optická koherenční tomografie	19
2 Základní přístroje pro zobrazování sítnice	22
2.1 Fundus kamera	22
2.1.1 Fluorescenční angiografie	23
2.1.2 Indocyaninová angiografie	24
2.2 RetCam3	25
2.3 Phoenix ICON	26
3 Principy klasifikace obrazových záznamů s využitím umělé inteligence	29
3.1 Segmentace obrazu	29
3.1.1 Rozdělení segmentací na základě sémantiky a interpretace	29
3.1.2 Základní metody segmentace obrazu	30
3.2 Klasifikace obrazu	31
3.2.1 Metody klasifikace obrazu	31
4 Metody pro detekci a kvantifikaci retinálních lézí	36
4.1 Historický vývoj umělé inteligence využívané v diagnostice retinopatie nedonošených	36
4.2 Semisupervizorní learningový přístup pro automatickou segmentaci retinálních lézí pomocí tzv. SURF detektoru a lokálně adaptivní binarizace	37
4.3 Využití rámce hlubokého učení pro detekci tzv. plus forem na retinálních snímcích předčasně narozených dětí	38
4.4 Vývoj automatizované vícerozměrné platformy využívající hlubokého učení snímků sítnice pro screening retinopatie nedonošených	40
4.5 Automatizovaná identifikace retinopatie nedonošených pomocí obrazového hlubokého učení	41

4.6	Automatizovaná detekce a klasifikace časných stádií ROP pomocí hluboké konvoluční neuronové sítě	43
4.7	Identifikace ROP s využitím konvoluční neuronové sítě s kombinovaným přístupem a extrakcí funkcí	44
4.8	Automatizovaná detekce retinopatie nedonošených prostřednictvím hluboké sítě.....	45
4.9	Algoritmus hlubokého učení pro automatickou diagnostiku ROP	46
4.10	Hodnotící kritérium pro retinální krvácení u novorozenců založené na hlubokých konvolučních neuronových sítích.....	47
5	Charakteristika použitých obrazových dat	50
5.1	Data pořízená systémem RetCam3	50
6	Návrh a realizace hybridního algoritmu	52
6.1	Algoritmus pro segmentaci retinálních lézí	52
6.1.1	Adaptivní binarizace následovaná morfologickými operacemi.....	52
6.1.2	Lokální detekce a deskripce prvků (SURF).....	54
6.1.3	Semisupervizorní identifikace	56
6.2	Algoritmus pro segmentaci cévního řečiště.....	58
6.2.1	Předzpracování obrazu.....	58
6.2.2	Segmentace obrazu	59
6.3	Implementace hybridního algoritmu.....	61
6.4	Postprocessing založený na kruhovitosti	64
7	Objektivní posouzení kvality algoritmu	65
7.1	Objektivizační parametry použité k objektivnímu posouzení kvality algoritmu.....	67
7.1.1	Strukturní index podobnosti (SSIM).....	67
7.1.2	Střední kvadratická chyba (MSE)	68
7.1.3	Korelační koeficient obrazu.....	68
7.2	Indikátory kvality použité k objektivnímu posouzení kvality algoritmu	68
7.2.1	Senzitivita	68
7.2.2	Specifická	69
7.2.3	Přesnost.....	69
7.3	Zhodnocení výsledků získaných objektivním posouzením kvality	69
7.4	Testování algoritmu s využitím různých prahových hodnot pro kruhovitost	73
8	Tvorba softwarového prostředí	77
	Závěr	83
	Seznam použité literatury	84
	Seznam příloh	87

Seznam použitých symbolů a zkratk

AI	Artificial Intelligence
cca	přibližně
CCD	Charge-coupled device
cm	centimetr
CNN	Convolutional Neural Networks
DCNN	Deep Convolutional Neural Networks
DICOM	Digital Imaging and Communications in Medicine
FC	Fully connected
FCN	Fully Convolutional Network
FNO	Fakultní nemocnice Ostrava
g	gram
GHz	gigahertz
HRT	Heidelberg retinální tomografie
JPEG	Joint Photographic Experts Group
kg	kilogram
kHz	kilohertz
lat.	latinsky
log.	logická
MHZ	megahertz
mm	milimetr
MSE	střední kvadratická chyba
např.	například
nm	nanometr
OCT	optická koherenční tomografie
RGB	aditivní barevný model
ROP	retinopatie nedonošených
RTA	analýza tloušťky sítnice
SSIM	strukturní index podobnosti
SURF	Speed Up Robust Feature
tzv.	takzvaný
USG	ultrasonografie
VA	voltampér

Seznam ilustrací

Obrázek 1: Různé druhy přímého oftalmoskopu [1]	14
Obrázek 2: Nepřímý oftalmoskop [3].....	15
Obrázek 3: Skenovací laserová oftalmoskopie výrobce EasyScan [17].....	16
Obrázek 4: Porovnání výsledných obrazů získaných pomocí dvou zobrazovacích metod [17].....	16
Obrázek 5: Trojrozměrné zobrazení zrakového nervu [11].....	17
Obrázek 6: HRT III od firmy Heidelberg Engineering [11]	18
Obrázek 7: Ukázka vyšetřovacích sond pro oftalmologii (zleva: A-scan, B-scan, UBM) [42]	19
Obrázek 8: A) zobrazení v A módu (osa x představuje vzdálenost jednotlivých očních struktur od sondy, osa y představuje míru akustického odrazu signálu na rozhraní optického prostředí), B) zobrazení očního nádoru pomocí B módu [8; 42]	19
Obrázek 9: Výstup pořízený optickou koherenční tomografií [9].....	20
Obrázek 10: OCT od firmy Heidelberg Engineering [9]	20
Obrázek 11: Fundus kamera Zeiss VISUCAM [6]	23
Obrázek 12: Další typ fundus kamery od firmy ZEISS [15]	24
Obrázek 13: Snímky pořízené před fluorescenční angiografií (nahore), snímky pořízené během fluorescenční angiografie (dole) [15].....	24
Obrázek 14: Systém RetCam3, upraveno podle [20]	25
Obrázek 15: RetCam Envision od firmy Natus [44].....	26
Obrázek 16: Systém Phoenix ICON (vlevo přenositelný, vpravo nepřenositelný) [21].....	27
Obrázek 17: Srovnání výsledných snímků pořízených kamerou Phoenix ICON (vlevo) a starším typem kamery (vpravo) [21]	27
Obrázek 18: Příklad metody K-means se třemi definovanými shluky [23]	33
Obrázek 19: Princip metody K-NN, Upraveno podle: [25]	33
Obrázek 20: Model neuronu, převzato z [27]	35
Obrázek 21: Vývojový diagram výše popsané metody (upraveno podle [30])	38
Obrázek 22: Znázornění normální zdravé sítnice (vlevo) a sítnice postižené plus formou onemocnění ROP (vpravo) [32]	39
Obrázek 23: Postup při tréninku dat (upraveno podle [32])	40
Obrázek 24: Design a proces výběru datového souboru, upraveno podle [34].....	42
Obrázek 25: Proces klasifikace a identifikace, upraveno podle [34]	43
Obrázek 26: Architektura použité hluboké neuronové sítě, upraveno podle [35].....	44
Obrázek 27: Postup navrhovaného systému [36].....	45
Obrázek 28: Struktura použitého modelu ResNet50, kde In_fea a Out_fea označují číslo kanálů vstupních a výstupních funkcí a FC označuje plně připojenou vrstvu [37]	46
Obrázek 29: Vývojový diagram modelu [38]	47
Obrázek 30: Přehled navrhovaných segmentačních sítí [39]	48
Obrázek 31: Reprezentativní příklady různých stupňů retinálního krvácení (zelené kruhy označují makulární oblast) [39].....	49
Obrázek 32: Graf znázorňující procentuální zastoupení diagnostikovaných onemocnění	50
Obrázek 33: Příklady jednotlivých diagnóz	51
Obrázek 34: Blokové schéma navrhovaného algoritmu	52
Obrázek 35: Postup při segmentaci retinálních lézí.....	52

Obrázek 36: Obrazové výstupy prvního celku segmentačního algoritmu lézí, A – vstupní snímek, B – extrahovaná zelená složka ve stupních šedi, C – výsledek po adaptivní binarizaci, D – výsledek po morfologických operacích	54
Obrázek 37: Příklady inicializačních (počátečních) masek	54
Obrázek 38: Princip výpočtu součtu využitím integrálního obrazu	55
Obrázek 39: Obrazové výstupy druhého celku segmentačního algoritmu lézí, A – mediánová filtrace zelené složky, B – lokace významných pixelů pomocí SURF detektoru, C – potvrzené léze detekované binarizací a současně SURF detektorem, D – pravděpodobné léze nedetekované SURF detektorem	56
Obrázek 40: Příklady výsledků získaných výše popsaným algoritmem.....	57
Obrázek 41: Sumarizace výše popsaného algoritmu, originální snímek (vlevo), segmentační masku (uprostřed), segmentované oblasti z originálního snímku (vpravo).....	57
Obrázek 42: Blokové schéma algoritmu určeného pro segmentaci cévního řečiště.....	58
Obrázek 43: Blokové schéma předzpracování obrazu	59
Obrázek 44: Obrazové výstupy procesu předzpracování.....	59
Obrázek 45: Blokové schéma segmentace obrazu	60
Obrázek 46: Obrazové výstupy segmentace obrazu.....	61
Obrázek 47: Blokové schéma hybridního algoritmu.....	61
Obrázek 48: Princip subtrakce, a) snímek získaný algoritmem pro segmentaci lézí, b) snímek získaný algoritmem pro segmentaci cév, c) snímek získaný odečtením snímku b od snímku a	62
Obrázek 49: Implementace morfologických operací, a) otevření s hodnotou strukturního elementu 100, b) uzavření se strukturním elementem tvaru disk a hodnotou parametru 5	63
Obrázek 50: Fúze dosavadních výsledků, a) znázornění odečtených (zelená barva) a přičtených (fialová barva) pixelů v rámci použití morfologických operací, b) znázornění segmentace nežádoucích částí.....	64
Obrázek 51: Blokové schéma postprocessingu	64
Obrázek 52: Výstupy získané navrhovaným postprocessingem, snímky získané subtrakcí (vlevo), snímek s nalezenými vnějšími okraji segmentovaných lézí a vyznačenou mírou kruhovitosti (uprostřed), konečný výsledek po implementaci algoritmu využívajícího kruhovitost (vpravo)	65
Obrázek 53: Fúze výstupů kruhovitosti.....	65
Obrázek 54: Porovnání výsledku získaného pomocí navrhovaného algoritmu (vlevo) a zlatého standardu vytvořeného na základě tohoto výsledku (vpravo).....	66
Obrázek 55: Příklad úspěšné detekce všech retinálních lézí přítomných v obraze	66
Obrázek 56: Příklad neúspěšné detekce retinálních lézí.....	67
Obrázek 57: Výsledky algoritmu s různým nastavením prahu pro kruhovitost v porovnání se zlatým standardem (GS).....	73
Obrázek 58: Příklady chybné segmentace při zvolení příliš nízkého prahu (0,50)	73
Obrázek 59: Graficko-uživatelské rozhraní navrhnuté v App Designeru	77
Obrázek 60: Vyskakovací okno pro výběr snímku	78
Obrázek 61: Otevření požadovaného snímku v aplikaci	78
Obrázek 62: Zobrazení segmentovaného cévního řečiště	79
Obrázek 63: Výběr z možností pro fúzi obrazu.....	79
Obrázek 64: Zobrazení fúzovaného snímku pro segmentaci cév	80
Obrázek 65: Výsledné zobrazení pro segmentaci retinálních lézí	80

Obrázek 66: Výsledné zobrazení hybridního algoritmu kombinující segmentaci cév a segmentaci lézí	81
Obrázek 67: Výsledné zobrazení po postprocesingu s hodnotou prahu 0,6	81
Obrázek 68: Vyskakovací okno s mírou kruhovitosti pro každý objekt zvlášť	82

Seznam tabulek

Tabulka 1: Technické parametry přímého oftalmoskopu [1]	15
Tabulka 2: Technické parametry indirektního oftalmoskopu [1]	15
Tabulka 3: Technické parametry přístroje EasyScan [17]	17
Tabulka 4: Technické parametry OCT od firmy Heidelberg Engineering [12]	21
Tabulka 5: Technické parametry fundus kamery Zeiss VISUCAM [6]	23
Tabulka 6: Technické parametry systému RetCam3 [20].....	26
Tabulka 7: Technické parametry systému Phoenix ICON [21]	28
Tabulka 8: Čtyři stupně krvácení podle velikosti R [39]	48
Tabulka 9: Procentuální zastoupení vyšetřovaných jedinců databáze Oční kliniky FNO v rámci dvou sledovaných parametrů	51
Tabulka 10: Hodnoty nastavené v algoritmu pro segmentaci lézí [30].....	58
Tabulka 11: Hodnoty nastavené v algoritmu pro segmentaci cév [19]	61
Tabulka 12: Tabulka zvolených parametrů pro morfologické operace hybridního algoritmu	62
Tabulka 13: Výsledky objektivního posouzení kvality pro zlaté standardy vytvořené na základě výsledků algoritmu s prahem 0,60.....	70
Tabulka 14: Výsledky objektivního posouzení kvality s využitím zlatých standardů obsahujících všechny léze detekovatelné pouhým okem	71
Tabulka 15: Rozdílové hodnoty vyjadřující pokles (respektive zvýšení v případě MSE) pro všechny parametry použité k objektivní analýze výsledků navrhovaného algoritmu s prahovou hodnotou kruhovitosti 0,60.....	72
Tabulka 16: Výsledky objektivního posouzení kvality pro algoritmus s prahem 0,50	74
Tabulka 17: Výsledky objektivního posouzení kvality pro algoritmus s prahem 0,70	75
Tabulka 18: Průměrné hodnoty parametrů a indikátorů kvality všech tří testovaných prahů	76

Úvod

Hlavním cílem této diplomové práce je vytvořit dostatečně kvalitní automatizovaný algoritmus pro detekci a extrakci retinálních lézí ze snímků očního pozadí předčasně narozených dětí pořízených systémem RetCam3 poskytnutých Oční klinikou FNO. Pod pojmem retinální léze (hemoragie) se rozumí patologické poškození retinálních cév, které vzniká poškozením celistvosti cévní stěny, které má za následek výstup krve z cév mimo retinální řečiště.

Teoretická část práce je zaměřena na základní principy a přístrojovou techniku používanou k zobrazení očního pozadí. Mezi nejčastěji využívané principy zobrazení zadního segmentu oka patří především oftalmoskopie, optická koherenční tomografie, fluorescenční angiografie či ultrasonografie. Pro stanovení diagnózy a sledování vývoje onemocnění v čase je rovněž nezbytné získat záznam očního pozadí v digitální či obrazové formě. Pro tento účel se u předčasně narozených dětí využívá systém RetCam3, RetCam Envision či Phoenix ICON. Další bod teoretické části je zaměřen na principy klasifikace obrazových záznamů s využitím prvků umělé inteligence.

Rešeršní část této práce je věnována metodám sloužícím pro detekci a kvantifikaci retinálních lézí. Veškeré níže zmíněné metody pojednávají o využití umělé inteligence v diagnostice ROP a využívají pro detekci retinálních lézí některou z forem učení, nejčastěji však učení hluboké.

V rámci praktické části, která tvoří nejdůležitější blok práce, jsou nejprve popsána použitá obrazová data. Dále je navrhnout a detailně popsán hybridní algoritmus pro extrakci retinálních lézí. Hybridní algoritmus je algoritmus kombinující více algoritmů. V této práci konkrétně dva, a to algoritmus pro segmentaci retinálních lézí a algoritmus pro segmentaci cévního řečiště. Tento přístup je zvolen pro dosažení co možná nejefektivnější extrakce pouze a jen oblastí retinálních lézí, neboť limitací algoritmu určeného pro segmentaci retinálních lézí je segmentace i oblastí reprezentujících cévní řečiště. Algoritmus určený pro segmentaci retinálních cév sestává z části pro předzpracování vstupního snímku a části pro samotnou segmentaci využívající metodu maximum principal curvature. Samotný hybridní algoritmus je realizován subtrakcí výsledků získaných pomocí segmentačních algoritmů. Po implementaci hybridního algoritmu následuje postprocessing založený na extrakci příznaků, konkrétně kruhovitosti výsledných objektů v obraze. Značná část praktické části je poté věnována objektivnímu posouzení kvality dosažených výsledků na základě objektivizačních parametrů a indikátorů kvality. Na závěr je vytvořeno graficko-uživatelské rozhraní sloužící k zobrazení výstupů z výše zmíněných algoritmů.

1 Základní principy pro zobrazování sítnice

Základními principy pro zobrazení zadního segmentu oka, tedy sítnice (lat. *retina*), cévnatky (lat. *uvea*) a terče zrakového nervu, se v dnešní době zabývá několik nejrozšířenějších zobrazovacích metod a to:

- Oftalmoskopie,
- Skenovací laserová oftalmoskopie,
- Heidelberg retinální tomografie (HRT),
- Ultrasonografie (USG),
- Optická koherenční tomografie (OCT) [1; 2; 21].

1.1 Oftalmoskopie

Oftalmoskopie je vyšetřovací metoda využívající dostatečně intenzivní světlo, které prochází skrze zornici, odráží se od pacientovy sítnice a vytváří výsledný obraz. V důsledku bohatého prokrvení cévnatky bude mít vzniklý obraz vždy nádech červeného zbarvení. Tento jev se odborně nazývá jako tzv. červený reflex. Podle vzdálenosti vyšetřovaného objektu od vyšetřovacího přístroje rozlišujeme přímou a nepřímou oftalmoskopii. Velkou výhodou obou zmíněných metod je jejich neinvazivní přístup [1].

1.1.1 Přímá oftalmoskopie

Přímá oftalmoskopie využívá ruční přenosné zařízení, tzv. oftalmoskop (Obrázek 1), a vyznačuje se malou vzdáleností (cca 2-7 cm) mezi vyšetřovaným objektem a oftalmoskopem. Podle sklonu oftalmoskopu, popřípadě změnou pohledového směru vyšetřovaného oka, je možné pozorovat oblast sítnice o velikosti přibližně 2 mm. Díky malému zornému poli je přímá oftalmoskopie známá svou detailností, avšak na druhou stranu je poměrně nepřehledná. Další nevýhodou je ztráta prostorového vnímání, neboť vyšetřovanou oblast pozoruje lékař pouze jedním okem. Výhodou přímého oftalmoskopu je možnost použití různých typů filtrů (záleží na výrobcu), které umožňují lepší výsledný snímek vyšetřované oblasti, např. použití zeleného filtru potlačuje červený reflex, který znemožňuje vyšetření nervových vláken sítnice. Základní parametry přímého oftalmoskopu jsou uvedeny níže (viz Tabulka 1) [1].



Obrázek 1: Různé druhy přímého oftalmoskopu [1]

Tabulka 1: Technické parametry přímého oftalmoskopu [1]

Světelný zdroj	LED dioda / xenonová žárovka
Napájení	bateriové / zdroj
Filtr	zelený, modrý, kobaltový
Rozpětí čoček v dioptrickém rozsahu	+ 44 D až – 45 D
Výsledný obraz	přímý, 16x zvětšený

1.1.2 Nepřímá oftalmoskopie

Nepřímá oftalmoskopie poskytuje vyšetření sítnice z větší vzdálenosti (cca 40-50 cm), než je tomu u oftalmoskopie přímé. Při tomto druhu oftalmoskopie se používá tzv. indirektní oftalmoskop (Obrázek 2) společně s vyšetřovací čočkou. Tato čočka je ve většině případech asférická (spojná) a vyšetřující jí přidržuje před okem vyšetřovaného ve vzdálenosti přibližně 3 až 9 cm. Samotný indirektní oftalmoskop má čelenkovité provedení, obsahuje zdroj intenzivního světla a je umístěn na čele vyšetřujícího. Tabulka 2 obsahuje základní technické parametry tohoto oftalmoskopu. Mezi výhody nepřímé oftalmoskopie patří binokulární princip vyšetření, díky kterému se neztrácí prostorové vnímání a zobrazení větší části sítnice, v rámci čemuž je vyšetření značně přehlednější [1].



Obrázek 2: Nepřímý oftalmoskop [3]

Tabulka 2: Technické parametry indirektního oftalmoskopu [1]

Světelný zdroj	LED dioda
Napájení	bateriové
Výsledný obraz	převrácený, 3x zvětšený

1.2 Skenovací laserová oftalmoskopie (SLO)

Skenovací laserová oftalmoskopie (Obrázek 3) je diagnostická zobrazovací metoda, která funguje na principu obrácené nepřímé oftalmoskopie a je určena k vyšetření zadní části oka. Jedná se o alternativní metodu pracující na bázi vysokorychlostního skenování bod po bodu. Skenování je uskutečněno díky laseru, který se pohybuje zleva doprava po sítnici, od které se světlo odráží a vytváří tak výsledný obraz rastrového typu. Ten je tvořen z 256 až 768 řad a sloupců, jejichž přesný počet je dán výrobcem a typem přístroje. Jeden bod zobrazované oblasti je osvětlen ani ne 1 μ s, takže během jedné sekundy je přístroj schopen pořídit 20 až 30 obrazů. Vysoká rychlost skenování snižuje oproti klasickému vyšetření fundus kamerou expoziční čas [2; 16; 17].




Obrázek 3: Skenovací laserová oftalmoskopie výrobce EasyScan [17]

Skenovací laserová oftalmoskopie se v praxi využívá k pozorování změn, které v oku vznikly v průběhu času, anatomickému popisu sítnice, vytvoření trojrozměrného obrazu oka skenováním v různých hloubkách a samozřejmě k detekci glaukomu. Může být použita i v kombinaci s fluorescenční angiografií, při které se pozoruje a měří čas, který barvivo potřebuje k uražení určité vzdálenosti skrz oční cévy. Tento čas je důležitý při posuzování rychlosti průtoku krve [2; 16].

Speciálním typem SLO je tzv. konfokální skenovací laserová oftalmoskopie, která vytváří a analyzuje trojrozměrný topografický obraz optického disku v reálném čase. Konfokální laserový oftalmoskop je dnes známý pod názvem Heidelberg retinální tomograf, který byl popsán výše [16; 17].

Skenovací laserový oftalmoskop od výrobce EasyScan, jehož technické parametry jsou uvedeny v tabulce níže (Tabulka 3), je vybaven kombinací dvou snímácích laserových paprsků. První, zelený laser o vlnové délce 532 nm, poskytuje zobrazení vnějších vrstev sítnice, kdežto druhý, infračervený laser o vlnové délce 785 nm, se používá k zobrazení vrstev vnitřních. Díky využití dvou vlnových délek je výsledný obraz detailnější, jasnější a kontrastnější v porovnání s klasickou retinální kamerou (viz Obrázek 4) [17].



Obrázek 4: Porovnání výsledných obrazů získaných pomocí dvou zobrazovacích metod [17]


Tabulka 3: Technické parametry přístroje EasyScan [17]

Rozměry	
Výška	445 mm
Šířka	322 mm
Hloubka	420 mm
Specifikace	
Optický motor	Confocal SLO
Režim snímání	zelený, infračervený, kombinovaný
Úhel pole	45°
Minimální velikost zornice	1,5 mm
Automatické zaostřování a snímání	ano
Formát obrazu	TIFF, JPEG, BMP, PNG, DICOM, PDF
Váha	< 11 kg

1.3 Heidelberg retinální tomografie

Heidelberg retinální tomografie je zobrazovací metoda, která umožňuje zobrazení, záznam a zhodnocení trojrozměrných obrazů zadního očního segmentu, jelikož je spojená s počítačovou analýzou vyšetřované oblasti. Používá se zejména při diagnostice terče zrakového nervu u pacientů trpících zeleným zákalem či při měření tloušťky sítnice. Samotné vyšetření je bezbolestné, nezatěžuje organismus pacienta a trvá přibližně 10 minut. Občas je však nutné před zahájením vyšetření pacientovi rozkapat oči mydriatiky, neboť přístroj funguje nejlépe při minimální šířce zornice 1,5 mm. Největším přínosem HRT je včasné zachycení ztráty nervových vláken a úbytku gangliových buněk [1; 2; 10; 11].

Přístroj funguje na principu laserového skenovacího systému, kdy monochromatický koherentní laserový paprsek, o vlnové délce 670 nm produkovaný diodovým zářičem, skenuje vyšetřovanou oblast a zaznamenává množství odraženého světla. Výsledný záznam je získán postupným snímáním mnoha ohniskových rovin, jejichž počet je dán tloušťkou vyšetřované oblasti (udává se 16 až 64), v různé hloubce zaostření. Výsledkem je tedy trojrozměrný obraz vyšetřované oblasti (Obrázek 5) či topografická mapa povrchu vyšetřované oblasti [2; 10; 11].



Obrázek 5: Trojrozměrné zobrazení zrakového nervu [11]

V současné době se nejvíce využívají přístroje druhé generace, známé pod zkratkou HRT II, které jsou vybaveny několika základními moduly. Prvním z nich je modul glaukomový používající se k diagnostice terče zrakového nervu. Druhým modulem je modul makulární poskytující informace týkající se žluté skvrny (lat. *macula lutea*). Tento modul se používá k vyšetření diabetické makulopatie, makulárního otoku či makulární degenerace. Dalším je modul rohovkový, který slouží

k optické pachymetrii, která se využívá k měření tloušťky rohovky. Heidelberg Retina Flowmeter je posledním modulem přístrojů HRT II, který slouží k měření pohyblivých částic (např. erytrocyty) krevního řečiště sledované oblasti sítnice. Nové a modernější přístroje HRT III (Obrázek 6) poskytují navíc vyhodnocení změn terče zrakového nervu v čase [1; 2; 10; 11].



Obrázek 6: HRT III od firmy Heidelberg Engineering [11]

1.4 Ultrasonografie

Ultrasonografie představuje nejvýznamnější aplikaci ultrazvuku v celém lékařství. Jedná se o neinvazivní zobrazovací metodu sloužící k zobrazení anatomické struktury buněčných tkání. Nejčastěji se tato metoda využívá v kardiologii, porodnictví, gynekologii a samozřejmě v oftalmologii. V očním lékařství se tento druh zobrazovací metody používá při vyšetření opticky nedostupných tkání či při diagnostice nádorových onemocnění [1; 7].

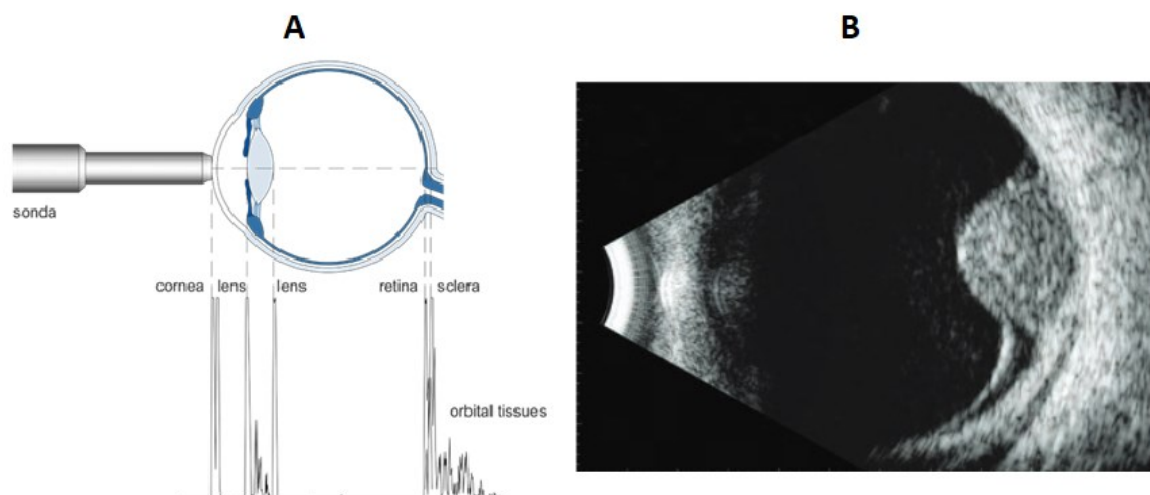
Při ultrasonografickém vyšetření oka jsou používány krátké zvukové vlny o frekvenci 12-20 MHz. Důležitou vlastností těchto vln je průchod skrz jednotlivé tkáně a jejich odraz na tzv. akustických rozhraních, která jsou charakteristická rozdílným akustickým odporem. Množství odražené energie je tím větší, čím větší je rozdíl akustických impedancí prostředí, které tvoří rozhraní. Odražená část vlnění se odborně nazývá jako echo a je přijímána ultrasonografickou sondou [1; 7].

V rámci oftalmologického ultrazvukového vyšetření je možné využívat tři typy sond (viz Obrázek 7). Prvním typem sondy je sonda, která obsahuje pouze jeden ultrazvukový měnič. Výsledný obraz, který je pomocí této sondy zaznamenán má jednorozměrný tvar, charakterizovaný pouze jedinou křivkou, a bývá označován jako A mód (A-scan). Výsledná křivka (Obrázek 8) je zobrazením výchylek, které vznikají odrazem ultrazvukových vln od jednotlivých očních struktur. Druhým typem sondy je tzv. B sonda, která slouží k pořízení dvojrozměrného zobrazení očních struktur (Obrázek 8). Toto zobrazení se nazývá jako B-scan a má sektorový charakter. Před použitím některé z těchto dvou výše zmíněných sond je potřeba provést topickou anestezii pomocí speciálních kapek pro znečítlivění rohovky, neboť se jedná o kontaktní zobrazovací metodu. To znamená, že sondu přikládáme přímo na oko pacienta. Kromě kapek je nezbytné využít i imerzní médium pro správné šíření ultrazvukového vlnění. Obsluha musí mít rovněž na paměti to, že při vyvinutí nadměrného tlaku na vyšetřované oko může dojít k jeho deformaci a tím i ke zkreslení samotného výsledku. Posledním typem

ultrasonografické sondy je sonda pro UBM. UBM je speciální ultrazukové vyšetření používající se pro zobrazení předního segmentu oka [1; 7].



Obrázek 7: Ukázka vyšetřovacích sond pro oftalmologii (zleva: A-scan, B-scan, UBM) [42]



Obrázek 8: A) zobrazení v A módu (osa x představuje vzdálenost jednotlivých očních struktur od sondy, osa y představuje míru akustického odrazu signálu na rozhraní optického prostředí), B) zobrazení očního nádoru pomocí B módu [8; 42]

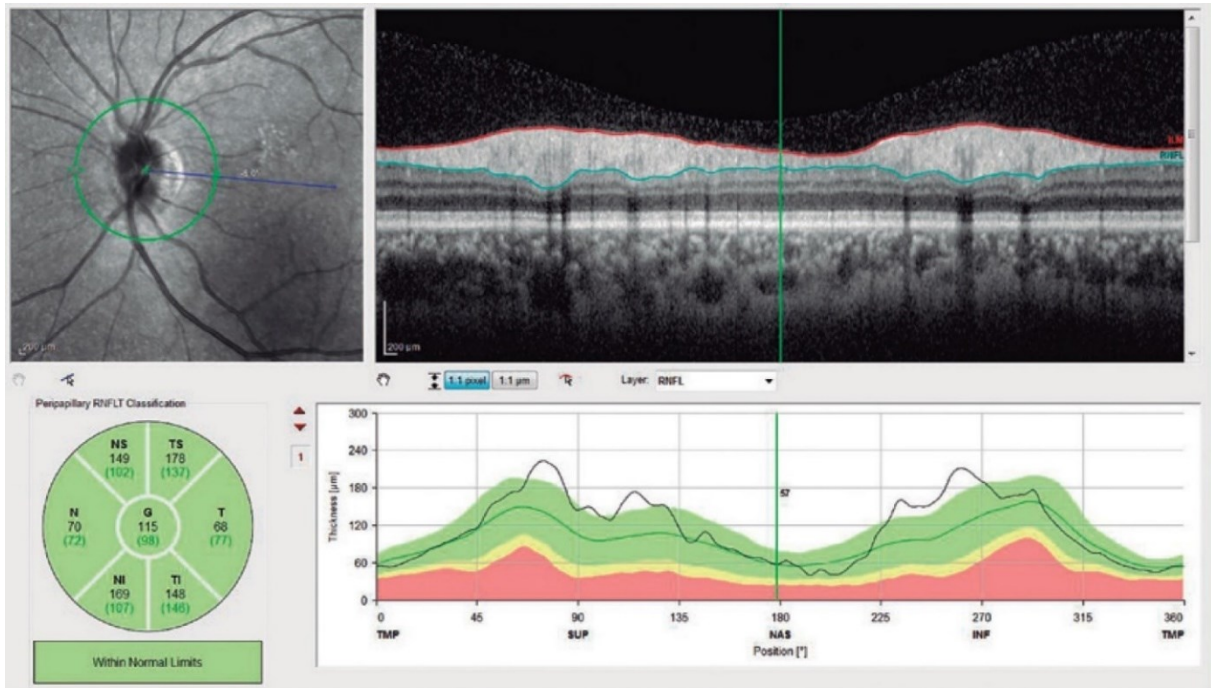
1.5 Optická koherenční tomografie

Optická koherenční tomografie, známá pod zkratkou OCT, je relativně mladá neinvazivní zobrazovací metoda používající se v oftalmologii za účelem dvourozměrného zobrazení optického řezu sítnice. Tato diagnostická metoda byla do klinické praxe uvedena v roce 1997. Od té doby byla vyvinuta řada nových generací, z nichž nejpoužívanější je dnes spektrální OCT, které umožňuje i vyšetření předního očního segmentu a poskytuje rozlišení 1-10 μm . Pro lepší představu uvedme, že například klasické ultrazukové vyšetření poskytuje rozlišení 150 μm [1; 2].

Metoda zobrazení funguje na principu odrazu vlnění od jednotlivých vrstev a tkání oka. Zdrojem vlnění je elektromagnetické záření (konkrétně infračervená část spektra) o vlnové délce přibližně 600 až 1300 nm. Vlnová délka ovlivňuje průnik světla do tkání. Platí, že čím je vlnová délka delší, tím větší je průnik světla. OCT je přístroj pracující na principu interferometru, měří dobu od vyslání referenčního paprsku až po jeho odraz od jednotlivých vrstev sítnice, které mají rozdílnou schopnost reflektivity. Referenční paprsek je obvykle produkován femtosekundovými lasery, popřípadě superluminiscenčními LED diodami. Paprsek vzniklý odrazem od jednotlivých struktur a tkání poté

dopadá na detektor. Měří se tedy časové zpoždění a velikost odraženého signálu. Výsledný snímek je zobrazený v předem smluvené barevné škále (viz. Obrázek 9). Jelikož OCT pracuje na principu odrazu světla, je pro samotné vyšetření velice důležitá dostatečná transparentnost tkání, uložených uvnitř oka. Rohovkový edém, hemoragie či zkalení čočky jsou komplikace, které vedou ke zhoršení výpovědní hodnoty vyšetření [1; 2].

Co se týče stavby, je OCT sestaveno ze štěrbinové lampy, zdroje infračerveného záření, videokamery, monitoru a speciálního Michelsonova interferometru (Obrázek 10). Nezbytnou součástí je i mechanická část, sestávající z opěrky brady a čela, sloužící k fixaci pacienta. Tabulka 4 obsahuje základní specifikace OCT [1; 2].



Obrázek 9: Výstup pořízený optickou koherenční tomografií [9]



Obrázek 10: OCT od firmy Heidelberg Engineering [9]

Tabulka 4: Technické parametry OCT od firmy Heidelberg Engineering [12]

Základní informace	
Vstupní napětí	100-240 voltů
Spotřeba energie	140 VA
Světelné zdroje	
FA laser	486 nm (modrá)
Zelený laser	518 nm (zelená)
ICGA laser	786 nm (infračervené)
IR laser	815 nm (infračervené)
OCT-SLD	880 nm (infračervené)
Čočka objektivu	
Max. skenovací pole	30° x 30° (cca 9 x 9 mm)
Průměrování obrázku	až 100 jednotlivých snímků
Zobrazení sítnice	
Skenovací rychlost	40 kHz / 80 kHz
Osová velikost digitálního obrazu	496 pixelů
Osové rozlišení	3,9 μm/pixel
Laterální rozlišení	5,7 μm/pixel
Skenovací úhel	až 55° (cca 16,5 mm)
Hloubka skenování	1,9 mm

2 Základní přístroje pro zobrazování sítnice

Tato kapitola bude věnována přístrojům, které se používají pro zobrazení a fotodokumentaci očního pozadí. V rámci kapitoly se zaměříme na Fundus kameru, systém RetCam3 a systém Phoenix ICON. Poslední dva zmíněné systémy mají oproti Fundus kameře tu výhodu, že umožňují vyšetření i imobilních pacientů či předčasně narozených dětí, kdežto při vyšetření pomocí Fundus kamery musí být pacient schopný sedět [19].

2.1 Fundus kamera

V dnešní době je běžná oftalmoskopie, ať už přímá či nepřímá, nahrazována technicky pokročilejšími přístroji, které umožňují záznam očního pozadí v digitální formě a zkracují dobu potřebnou pro diagnostiku. Příkladem těchto přístrojů je fundus kamera (Obrázek 11), často nazývaná jako retinální nebo sítnicová kamera, která pracuje na obdobném principu jako nepřímá oftalmoskopie. Fundus kamera je hojně využívána v celé škále oftalmologických vyšetření jako je např. vyšetření diabetické retinopatie, ROP, zeleného zákalu či degenerativních změn oka. Taktéž se snímky pořízené fundus kamerou používají pro sledování nálezu v čase. Přístroj pracuje na neinvazivním principu zobrazení očního pozadí či předního segmentu oka v zorném poli 20° – 50° [1; 4].

Existují dva typy těchto kamer. První z nich, mydriatické fundus kamery, vyžadují aplikaci speciálních mydriatických kapek, které mají za úkol rozšířit zornici pacienta pro lepší snímkování a zobrazování sítnice a přilehlých částí oka. Značnou nevýhodou mydriatik je zhoršení zraku až na několik hodin. Druhým typem jsou nonmydriatické fundus kamery, které fungují i bez použití mydriatik, a právě z toho důvodu jsou v běžné praxi více oblíbené [4; 5].

Z hlediska stavby je fundus kamera rozdělena na dvě základní části. Část mechanická sloužící k fixaci pacienta a část optická sestávající z kamery a mikroskopu. Fixace pacienta je potřebná z důvodu redukce nežádoucích pohybových artefaktů, které znehodnocují výsledný obrazový záznam. Pro co nejkvalitnější potlačení těchto artefaktů, jsou dnešní moderní fundus kamery vybaveny speciálním softwarem pro automatické zaměření středu sítnice [4].

Každá fundus kamera obsahuje zdroj bílého neutrálního světla, které prochází skrz rohovku, zornici a čočku až k sítnici pacienta, osvětluje ji, odráží se od ní a vytváří výsledný obraz, který je nutné zaznamenat. K obrazovému záznamu se používá, jak již bylo zmíněno výše, speciální kamera, mikroskop sestávající ze systému čoček a zrcadel, umožňující fokusaci paprsků na oční pozadí, a CCD snímače, které zachycují odražené světlo. Veškeré technické parametry jsou uvedeny níže (Tabulka 5) [1; 4; 5].

Výsledný snímek je přímý, zvětšený a lze je kdykoliv zobrazit či exportovat ve formě JPEG či ve formátu DICOM, neboť je uchováván v obrazové databázi [5].

Fundus kamera se rovněž používá i při focení speciálního vyšetření s kontrastní látkou. Jedná se o tzv. angiografii, při které se mohou použít dva typy barviv – fluorescein či indocyaninová zeleň. Oba typy angiografie jsou popsány v následujících podkapitolách [14; 15; 43].



Obrázek 11: Fundus kamera Zeiss VISUCAM [6]

Tabulka 5: Technické parametry fundus kamery Zeiss VISUCAM [6]

Zorné pole	Funkce
Režim snímání	20°, 30° a 50°
Filtr	barevný, bezčervený, modrý, červený
Kompensace zrakových vad	bariérový UV/IR, zelený
Snímací sekvence	kontinuální, +35 D...-30 D od 1,5 sekundy
Operační systém	Počítač
Pevný disk	Windows Embedded Standard 7
Rozhraní	možnost uložení přibližně 80 000 obrázků (současná velikost pevného disku: 420 GB)
Export/import	USB, DVI, síťové konektory
	JPEG, TIFF, VL, DICOM


2.1.1 Fluorescenční angiografie

Fluorescenční angiografie (FAG) je vyšetřovací metoda sloužící k vyšetření cévního řečiště sítnice pomocí speciální kontrastní látky zvané fluorescein. Ten je pacientovi aplikován před samotným vyšetřením do kubitální žíly (intravenózně) a jeho úkolem je zvýraznit cévní řečiště. Při fyziologickém stavu se fluorescein nevyskytuje mimo řečiště, kdežto při stavu patologickém, při němž dojde k porušení cévní stěny, se objeví tzv. hyperfluorescenční ložiska. Ta mohou vznikat jako následek mikroaneurysmat, edému či neovaskularizací. Někteří pacienti mohou být na fluorescein alergičtí. Z toho důvodu je možné použít jako alternativu indocyaninovou zeleň, která má stejný účinek [14; 15].

Sítnice se snímá buď pomocí fundus kamery (Obrázek 12) nebo pomocí OCT a výsledky se používají především při diagnostice diabetické retinopatie, nitroočních nádorů, neprůchodnosti žil a artérií, popřípadě vrozených či získaných degenerativních změn. Obrázek 13 znázorňuje fyziologické snímky pořízené fluorescenční angiografií [14; 15].



Obrázek 12: Další typ fundus kamery od firmy ZEISS [15]



Obrázek 13: Snímky pořízené před fluorescenční angiografií (nahore), snímky pořízené během fluorescenční angiografie (dole) [15]

2.1.2 Indocyaninová angiografie

Indocyaninová angiografie (ICGA) je stejně jako FAG vyšetřovací metoda sloužící k vyšetření cév sítnice. Její hlavní výhodou je specifická analýza choroideálního řečiště, u kterého je podstatná především jeho interakce se sítnicí. Malé množství barviva je pacientovi opět podáno intravenózně. Na rozdíl od FAG, která trvá přibližně 10 minut, je doba trvání ICGA cca 20-30 minut. V rámci této vyšetřovací doby je opět pomocí fundus kamery či OCT získávána série fotek a videí. Metoda ICGA může být použita jako doplnění fluorescenční angiografie a obě vyšetřovací metody je možné provádět současně. ICGA se nejčastěji používá při vyšetření některých typů vlhké formy věkem podmíněné makulární degenerace [43].


2.2 RetCam3

Systém RetCam3 (Obrázek 14) patří mezi zobrazovací metody určené pro screening sítnice. Jeho použití je možné jak u dospělých lidí, u kterých se sledují zejména očních anomálií či nádory oka, tak primárně u dětí, což se hojně využívá při diagnostice retinopatie nedonošených, zkráceně ROP. Tato nemoc se může objevit při nedostatečné zralosti novorozence a projevuje se nedokonalým vývojem očních struktur, zejména sítnicových cév [18; 19].

Přístroj RetCam3 má řadu výhod. První z nich je možnost volby z pěti vyměnitelných objektivů, které se vyznačují rozdílným zorným polem (130°, 120°, 80°, 30°, posledním je objektiv portrétový). U dětských pacientů se z pravidla nejvíce používá 120stupňový pohled. Oproti běžné nepřímé oftalmoskopii tak dostáváme až 4x větší zorný úhel. Další výhodou je možnost použití přístroje pro vyšetření již dvoutýdenního novorozence. Dále umožňuje pořízení záznamu ve formě fotografie s vysokým rozlišením 1024 x 468 pixelů či 2minutového videozáznamu, který je pořízen s využitím CCD kamer, jejichž pořizovací rychlost je 30 snímků/sekunda (10 bit/pixel). Všechny záznamy jsou uchovávány v digitální podobě. V neposlední řadě umožňuje pozorování časového vývoje onemocnění a vzdálenou komunikaci s dalšími odborníky [18; 19].

Přístroj se skládá z plně integrovatelného mobilním vozíku, který lékaři dovoluje vyšetřit i imobilní pacienty. Sítnice je kamerou zobrazena v přímé nepřevrácené barevné podobě, což eliminuje možné chyby vyšetřujícího. Tabulka 6 obsahuje technické aspekty systému RetCam3 [18; 19].

V současné době se přechází ze systému RetCam3 na tzv. RetCam Envision (Obrázek 15), který představuje novou generaci pediatrického očního zobrazování. Tato generace systému RetCam poskytuje ultra široké zorné pole (konkrétně 130°) a obsahuje vylepšené osvětlení, tzv. technologie Light Shaping, která zlepšuje periferní osvětlení i osvětlení tmavě pigmentovaných sítnic. Tyto vlastnosti umožňují pořízení velmi kvalitních snímků, které poskytují vyšší úroveň spolehlivosti pro následné hodnocení. Tento nový systém rovněž poskytuje bezpečné uložení snímků centrálně díky integraci PACS [44].



Obrázek 14: Systém RetCam3, upraveno podle [20]

Tabulka 6: Technické parametry systému RetCam3 [20]

Počítač	
Operační systém	Windows 7
Procesor	Pentium Dual Core 2,4 GHz
Připojení	LAN/Multi USB
Hadr disk	1 TB
Systémová paměť	4 GB
Integrovaný mobilní vozík	
Monitor	21" x 23"
Pracovní deska	41"
Pracovní plocha	230 čtverný inch
Zobrazení monitoru	23"
Napájení	napájecí kabel, baterie
Tiskárna	kombinace klasické tiskárny s fototiskárnou
Baterie	záložní, provoz 15 min
Příslušenství	Fluorescenční modul pro angiografii, 4 uzamykatelné zásuvky



Obrázek 15: RetCam Envision od firmy Natus [44]

2.3 Phoenix ICON

Novým typem retinálního zobrazovacího systému je ruční sítnicový systém Phoenix ICON, který poskytuje snímky s vysokým rozlišením a vysokým kontrastem. Stejně jako systém RetCam umožňuje vyšetření všech věkových kategorií. Této skutečnosti se opět využívá u onemocnění ROP, u kterého se provádí screening očí novorozenců [21].


Systém Phoenix se vyznačuje vyměnitelnými světelnými moduly, přičemž intenzita světla, které dopadá na pacientovu sítnici, je výrazně nižší než u starších systémů. Další výhodou je tzv. dvojitý provedení. Sám uživatel si může zvolit, jestli si chce systém Phoenix ICON pořídit v přenositelném či

nepřenositelném provedení. Obrázek 16 znázorňuje systém přenositelný, který se využívá především pro dálkové prověřování a sám lékař je schopen přístroj pohodlně přemístit z jednoho konce nemocnice na druhý. V opačném případě je systém umístěn na integrovaném pojízdném vozíku, podobně jako systém RetCam (viz Obrázek 16). Je tedy patrné, že systém Phoenix ICON je možné použít jak na operačních sálech, tak i na klinikách či na nemocničních odděleních [21].



Obrázek 16: Systém Phoenix ICON (vlevo přenositelný, vpravo nepřenositelný) [21]

Phoenix ICON umožňuje pořizování výsledných záznamů ve formě fotografií, videí nebo FlashBack videí pomocí intuitivního uživatelského rozhraní. Výsledné záznamy jsou pořizovány speciální kamerou s plně osvětleným 100° zorným polem. Inovací je i samotný osvětlovací mechanismus, neboť vyšetřovaná oblast je osvětlena přímo tzv. prstencovým osvětlením (má tvar prstence). To ponechává střed světelné dráhy otevřený pro zpětné světlo, které se odrazilo od samotné sítnice. Tento způsob osvětlení má za následek pořízení výsledných snímků s vysokým rozlišením a vysokým kontrastem (viz Obrázek 17). Velkým přínosem v době, kdy svět sužuje onemocnění Covid-19, je možnost dezinfekce vyšetřovací hlavičky pomocí vestavěného namáčecího pohárku. Dezinfekce je řízena speciálním zabudovaným softwarem a je nutné ji provést po vyšetření každého pacienta. Tabulka 7 poskytuje technické parametry systému Phoenix ICON [21].



Obrázek 17: Srovnání výsledných snímků pořízených kamerou Phoenix ICON (vlevo) a starším typem kamery (vpravo) [21]

Tabulka 7: Technické parametry systému Phoenix ICON [21]

Vlastnosti počítače

Operační systém	Windows 10
Frekvence procesoru	2,4 GHz
Velikost paměti RAM	16 GB
Pracovní frekvence RAM	1600 MHz
Vstupní/výstupní porty	USB 3,0 a RJ-45 Ethernet

Integrovaný mobilní vozík

Display	21,5"
Rychlost snímání	30 snímků za sekundu
Pracovní plocha	18" x 14"
Napájení	napájecí kabel, baterie
Baterie	výdrž až 6 hodin mezi nabitími
Příslušenství	klávesnice, nožní pedál, výsuvná zásuvka

3 Principy klasifikace obrazových záznamů s využitím umělé inteligence

Tato kapitola se zabývá klasifikačními technikami, které se používají jak pro klasifikaci, tak pro segmentaci objektů z obrazu. Před popisem jednotlivých technik, je důležité si uvědomit rozdíl mezi segmentací a klasifikací. Oba tyto pojmy si jsou velice podobné, ale laicky by se dalo říct, že klasifikační algoritmus je oproti algoritmu segmentačnímu sofistikovanější.

3.1 Segmentace obrazu

Segmentační algoritmus je algoritmus, který detekuje oblasti obrazu, ve kterých se vyskytuje námi zvolená oblast zájmu (např. retinální léze, optický disk, retinální cévy apod.), která se vyznačuje homogenitou jasového spektra. U segmentace je důležitá apriorní znalost problému, to znamená, že čím více informací o oblasti zájmu mám, tím lépe mohu zvolit parametry segmentační procedury. Vstupem je intenzitní obraz, který disponuje určitým spektrem jasových intenzit, které je poté rozděleno do jednotlivých skupin a výstupem je tzv. segmentační mapa. Segmentace je tedy skupina metod sloužících k automatickému rozdělení (dekompozici) obrazu na jednotlivé oblasti, které se vyznačují společnými vlastnostmi. Pojem segmentace obrazu se dá rovněž chápat i jako soubor matematických strategií (algoritmů), které dokážou detekovat zvolený objekt v obraze. Z hlediska rozdělení je můžeme separovat do dvou hlavních podskupin. První skupina jsou tzv. konvenční metody, jelikož zahrnují konvenční matematické principy. Druhou skupinou, která v dnešní době pomalu nahrazuje metody konvenční, jsou tzv. metody hybridního charakteru. Tyto metody fungují na konvenčním přístupu, který je nejčastěji optimalizován pomocí metod umělé inteligence, a tím jsou schopny dosahovat lepších výsledků. Nevýhodu však mají v tom, že jsou algoritmicke a výpočetně mnohem náročnější než metody konvenční. Obecným problémem u všech segmentačních metod je variabilita dat. Proto je vždy nutné otestovat robustnost segmentačního algoritmu. Konkrétními příklady konvenčních segmentačních metod jsou: klasické prahování, detektory hran, aktivní kontury a další. Všechny tyto metody vyžadují nastavení několika parametrů či počáteční inicializaci. Právě z toho důvodu se v dnešní době od těchto metod upouští a do popředí se dostávají metody využívající umělé neuronové sítě. Výhodou těchto segmentací je to, že nevyžadují specifikaci kritérií, které mají dodržovat. Potřebují pouze dostatečné množství správně klasifikovaných dat [24; 28].

3.1.1 Rozdělení segmentací na základě sémantiky a interpretace

V této kapitole budou segmentační metody rozděleny do tří základních skupin podle toho, zda řeší či neřeší problém interpretace a sémantiky. Oba tyto pojmy se pojí s definicí regionu, kdy region je chápán jako shluk pixelů se společně sdílenými vlastnostmi (např. poloha, charakteristika textury tkáně atd.). Pojem interpretace souvisí s charakteristikou regionu a říká nám, zda daná metoda je či není schopna interpretovat, co každý region je a jakou tkáň či objekt představuje. Naopak sémantika nám definuje to, co je segmentační metoda schopna z obrazu extrahovat, jestli celý obraz jako celek či jeden konkrétní objekt [24].

3.1.1.1 Konvenční segmentace

Konvenční segmentace, známá i pod názvem segmentace bez interpretace či nesupervizorní segmentace, je typ segmentace, která neřeší problémy interpretace (jak vyplývá už ze samotného názvu). Z toho plyne její zásadní nevýhoda a to ta, že získaný výsledek musí být interpretován odborníkem na dané téma. Mezi tento typ segmentace řadíme například prahování či shlukování (FCM, K-means) [24].

3.1.1.2 Sémantická segmentace

Sémantická segmentace neboli segmentace s interpretací či supervizorní segmentace, je metoda, která má na pozadí neuronovou síť, která využívá hlubokého učení (deep learning). Z názvu je opět zřejmé, že tento druh metody umí říct (interpretovat), co každý region představuje. Výhodou je tedy možnost segmentace jednoho konkrétního objektu v obraze nikoli celého obrazu, jak tomu bylo u segmentace konvenční. Na druhou stranu je v důsledku využití neuronové sítě potřeba provést tzv. trénovací fázi, v rámci které, se na velkém objemu dat naučí rozpoznávat daný konkrétní objekt na základě apriorní informace (nejčastěji s využitím učení s učitelem). Mezi nejčastěji používané neuronové sítě v rámci segmentace patří např. U-net, SegNet či FCN (fully convolutional network) [24; 28].

3.1.1.3 Semisupervizorní segmentace

Semisupervizorní segmentace je polointeligentní hybridní kombinace dvou předchozích typů segmentací. V podstatě se jedná o redukovanou formu sémantické segmentace, jelikož se zde nevyužívá tak velkého objemu dat a rovněž se zde využívá částečného učení (na redukovaném datasetu), které spočívá ve dvou krocích. Prvním krokem je tzv. předsegmentace, v rámci které, se provede částečné naučení a poté následuje fúzování příznaků z tréninku předurčené neuronové sítě s dalšími reálnými obrazy, které se již netrénují, ale jsou nezbytné k vnitřnímu doučení sítě. Tyto hybridní kombinace se snaží vynahradiť nedostatky sémantické segmentace ve smyslu zdlouhavé trénovací fáze způsobené velkým objemem dat [24].

3.1.2 Základní metody segmentace obrazu

V současné době existuje nepřeberné množství způsobů, jak segmentaci obrazu provést. Základní segmentační metody můžeme rozdělit do čtyř základních podskupin [24; 28].

3.1.2.1 Metody založené na prahování

Tyto metody patří mezi nejjednodušší a nejstarší segmentační metody, které se hojně využívají především kvůli tomu, že jejich algoritmy nejsou obzvláště složité. Hlavní parametr, který definuje výsledný obraz je tzv. práh. Tento práh nám definuje pomyslnou hranici mezi popředím a pozadím. Volba velikosti prahu se provádí buď automaticky nebo manuálně, ale manuální nastavení prahu není příliš přesné a z toho důvodu se příliš nepoužívá. Příkladem automatického prahování je tzv. Otsu metoda, která stanovuje optimální hodnotu prahu pomocí rozptylu (racionální logiky). Příkladem sofistikované prahovací metody je tzv. soft (měkké) prahování, které funguje na základě fuzzy funkcí příslušnosti, do kterých se řadí metoda K-means či FCM [24; 28].

3.1.2.2 Regionální metody založené na podobnosti pixelů v určité vlastnosti

Regionální metody využívají pro segmentaci obrazu podobnosti sousedních pixelů, např. jas. Metody fungují na základě rozmístění tzv. iniciálních pixelů, které se dále iterativně rozrůstají po okolí, které se vyznačuje stejnými vlastnosti jako iniciální (počáteční) pixel. Nevýhodou však může být segmentace částí, které do výsledku vůbec nepatří, ale byly zaneseny šumem [24; 28].

3.1.2.3 Metody založené na hranicích (detekce hran)

Metody založené na detekci hran využívají prudké změny jasu v určitých místech obrazu. Tato místa se nazývají jako tzv. hrany a je nutné je detekovat pro správné vymezení objektu zájmu. K detekci hran se využívají tzv. gradientní operátory, mezi které patří např. Cannyho hranový detektor, Sobelův operátor, operátor Prewittové, Laplaceův operátor či Robertsův operátor [24; 28].

3.1.2.4 Pokročilejší metody

Mezi pokročilejší segmentační metody patří např. aktivní kontury či segmentace rozvodím. Aktivní kontury jsou poměrně složité metody, které vyžadují inicializaci ve formě startovací kontury, která je manuálně umístěna vně segmentovaného objektu. Startovací kontura se dále rozrůstá na základě počtu iterací, které si operátor sám nastaví. Na druhou stranu segmentace rozvodím chápe vstupní obraz jako reliéf, ve kterém je jas každého pixelu chápán jako jakási nadmořská výška, na základě, které se obraz postupně zaplavuje [24; 28].

3.2 Klasifikace obrazu

Na druhou stranu klasifikační algoritmus je algoritmus, který nic přímo nedetekuje, pouze rozpoznává a určuje, zda je/není daný objekt součástí naší zájmové oblasti podle toho, co má naučené. K samotnému „naučení“ je vždy potřeba tzv. množina trénovacích dat. Tato množina obsahuje data (snímky) se správně určenými kategoriemi daného problému. Rovněž je algoritmus schopen určit vlastnosti námi klasifikované oblasti. U klasifikačních algoritmů se můžeme často setkat s pojmem klasifikátor. Tento pojem neznamená nic jiného než algoritmus, který implementuje klasifikaci. Rovněž se můžeme setkat s pojmem klasifikační třída, která představuje množinu objektů se sdílenými vlastnostmi. V oblasti retinopatie nedonošených se klasifikace obecně využívá zejména k rozpoznávání toho, zda na daném snímku je či není počínající retinopatie [25].

3.2.1 Metody klasifikace obrazu

V důsledku toho, že se samotná klasifikace řadí do metod umělé inteligence, která je v současné době velice oblíbená, není žádným překvapením, že klasifikační metody začínají pomalu ale jistě nahrazovat klasické segmentační metody. Velkou výhodou metod umělé inteligence je nevyužívání tvrdě nastaveného algoritmu, nýbrž využití inteligentních principů s adaptibilní strukturou. Opět se zde využívají speciální druhy neuronových sítí, které jsou určeny přímo pro klasifikaci obrazu. Mezi tyto dostupné předtrénované sítě patří např. squeezeNet, resnet50, darknet19 či vgg16 [25].

3.2.1.1 Shluková analýza

Shluková analýza tvoří pomyslný most mezi metodami statickými a metodami umělé inteligence. Používá se jak pro klasifikaci objektů v obrazu, tak pro jeho segmentaci. Hlavním principem je rozdělení vstupních komplexních dat do jednotlivých tříd (regionů). V obrazové doméně tedy slouží k rozdělení objektů v obraze do tzv. shluků, které jsou charakteristické tím, že sdílí vlastnosti jednotlivých objektů. V podstatě se pomocí shlukové analýzy snažíme zachytit jakousi homogenitu objektů, přičemž vzniklé shluky reprezentují sdílené vlastnosti napříč celým objektem [22; 23].

Základním parametrem, který určuje podobnost dvou či více objektů navzájem je tzv. míra (ne)podobnosti objektů. U tohoto parametru platí komutativní zákon. To znamená, že nezáleží na tom, jestli porovnávám objekt A vůči objektu B nebo objekt B vůči objektu A. Výsledek bude vždy stejný. Ke stanovení míry (ne)podobnosti objektů se nejčastěji využívají tzv. atributy. V rámci této práce budou představeny dva základní atributy. Prvním z nich je tzv. binární atribut, který rozhoduje o tom, zda daný objekt má (výsledkem bude log. 1) nebo nemá (výsledkem bude log. 0) danou vlastnost. Tento atribut tedy nenabývá záporných hodnot, ale jeho hlavní nevýhodou je to, že poskytuje informace pouze o tom, zda daný objekt patří či nepatří do daného shluku, v podstatě se jedná o tvrdou klasifikaci. Druhým sofistikovanějším atributem je reálně-hodnotový atribut, který určuje míru přiřazení objektu do daného shluku. Opět zde platí komutativní zákon a opět nabývá

nezáporných hodnot s tím, že platí, že čím je atribut větší, tím je nepodobnost mezi objekty větší. Obecně se tento přístup nazývá jako tzv. numerická kvantifikace [22].

U shlukové analýzy se lze často setkat s problémem, kdy je třeba zjistit, zda si dva shluky nejsou tak podobné, že by se mohly spojit. K tomuto účelu slouží různé metody, které jsou tento problém schopny kvantifikovat:

3.2.1.1.1 Hierarchické metody shlukování

Hierarchické metody pracují na principu posloupnosti rozkladů. Na začátku máme shluk, který obsahuje všechny objekty a na konci dostaneme jednoprvkové shluky. Tento typ shlukování se používá převážně pro nalezení struktury než pro vyhledávání nových vzorů. Mezi nejčastěji používané hierarchické metody patří metoda nejbližšího souseda a centroidní metoda [22; 23].

- Metoda nejbližšího souseda

Tato metoda spočívá v nalezení nejmenší vzdálenosti mezi dvěma objekty, z nichž každý patří do jiného shluku. V podstatě se jedná o vytvoření shluku z objektů nebo shluků, které mezi sebou mají nejmenší vzdálenost. Nevýhodou této metody je to, že může dojít k tzv. zřetězení v důsledku existence objektů, které mají stejnou vzdálenost od již existujícího shluku [22].

- Centroidní metoda


Zmíněná metoda řeší míru nepodobnosti shluků na základě analýzy těžišť s využitím Euklidovské metriky, která stanovuje míru podobnosti námi zvoleného parametru (např. jasového spektra, velikosti objektu). Každý shluk (i segmentační třída) je charakterizován svým vlastním těžištěm (centroidem), které se vypočítá jako aritmetický průměr hodnot shluků. Následně dojde ke sloučení shluků, které mají mezi svými těžišti nejmenší vzdálenost [22; 23].

3.2.1.1.2 Nehierarchické metody shlukování

Nehierarchické metody nevytváří hierarchickou strukturu a nehledají přesnou posloupnost dat, ale snaží se data rozdělit do shluků na základě míry podobnosti. Tyto metody se dají opět rozdělit podle toho, jaké učení využívají, a to na supervizorní a nesupervizorní metody. Supervizorní metody využívají učení s učitelem a jsou na základě tréninku schopny rozeznat jednotlivé objekty. Na druhou stranu metody nesupervizorní využívají učení bez učitele a nepotřebují tudíž trénovací dataset. V rámci klasifikace obrazu se nejčastěji používají metody nesupervizorní, mezi které patří metoda K-means a metoda Fuzzy C-means (FCM) [22].

- Metoda K-means

U této metody je v prvním kroku potřeba definovat počet shluků (K), na které chci obraz rozdělit. Podle zvoleného počtu shluků se v průřezu dat náhodně umístí těžiště shluků, do kterých se následně na základě Euklidovské vzdálenosti přiřazují jednotlivé objekty. Jakmile jsou shluky naplněné, dojde k přepočítání těžišť a celý proces se opakuje. Přepočet se zastaví až při dosažení tzv. konvergenčního kritéria, které se stanoví z dvou po sobě jdoucích iterací, ve kterých nedošlo k žádné změně (bylo dosaženo stabilního stavu). Princip metody K-means je znázorněn níže (viz Obrázek 18) [22; 23].



Obrázek 18: Příklad metody K-means se třemi definovanými shluky [23]

- Fuzzy C-means

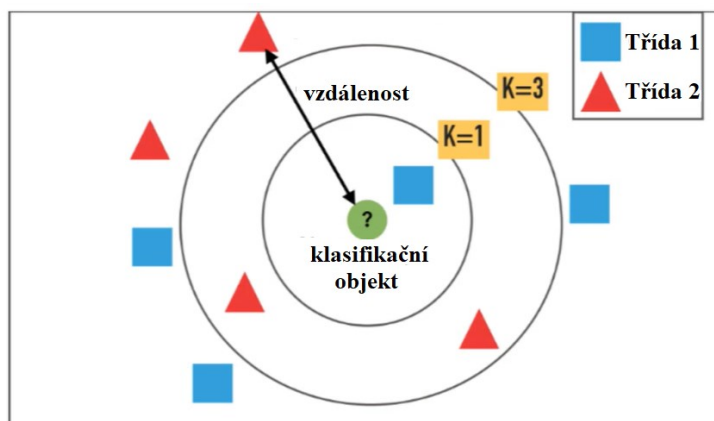
Tato metoda umožňuje shlukování do více než jednoho shluku na základě stupně členství. Její výhodou je to, že nevyužívá tvrdé klasifikace, jak je tomu například u metody K-means, ale využívá funkcí příslušnosti. Nenabývá tudíž pouze hodnot 1 a 0, ale nabývá hodnot od 0 do 1 s tím, že platí, že čím vyšší hodnota, tím větší síla přiřazení k danému shluku. Oproti metodě K-means je rovněž robustnější a u biomedicínských dat dosahuje lepších výsledků [22; 23].

3.2.1.2 Učení s učitelem

Učení s učitelem neboli supervizorní učení je metoda strojového učení, která využívá apriorní informace, se kterou algoritmus funguje. Je zde využito trénovací množiny sestávající ze vstupních objektů a požadovaného výstupu. Důležitou součástí trénovací fáze je tzv. fáze verifikační v rámci které, se posuzuje kvalita natrénování. Je tedy posuzována shoda výsledků získaných tréninkem s požadovanými výstupy [25].

- K-NN (K-Nearest Neighbours)

Metoda K-NN známa taky pod názvem metoda nejbližšího souseda je nejjednodušší klasifikace pro učení s učitelem. Metoda se snaží o klasifikaci dat na základě minimální vzdálenosti mezi klasifikovaným objektem a trénovací množinou (viz Obrázek 19). Samotná klasifikace se provádí na základě největší četnosti nejbližších výskytů [25].



Obrázek 19: Princip metody K-NN, Upraveno podle: [25]

3.2.1.3 Učení bez učitele

Stejně jako učení s učitelem je i učení bez učitele neboli nesupervizorní učení metodou strojového učení. Oproti předchozí metodě nevyužívá žádné apriorní informace. To znamená, že na vstupu nemá data provázaná s cílovou proměnnou. Úkolem této metody je opět seskupit objekty podle podobnosti, přestože nejsou k dispozici žádné klasifikační kategorie. Algoritmus nesupervizorního učení analyzuje základní strukturu dat na základě extrakce užitečných informací nebo funkcí. Očekává se tedy, že tento algoritmus bude vyvíjet konkrétní výstupy z nestrukturovaných vstupů hledáním vztahů mezi každým prvkem nebo vstupním objektem. Obecně platí, že metody učení bez učitele jsou schopny vykonávat složitější úlohy zpracování než metody supervizorní, avšak mohou být více nepředvídatelné [26].

3.2.1.4 Neuronové sítě

Umělé neuronové sítě jsou inspirovány biologickými neuronovými sítěmi a jedná se o jeden z výpočetních modelů, které můžeme používat při tvorbě umělé inteligence. Co se týče stavby neuronových sítí, tak se mohou skládat buď z jednoho (tzv. perceptron) nebo více neuronů (rekurentní neuronová síť, Kohonenovy mapy). Model neuronu je znázorněn níže (Obrázek 20). Jejich velkou výhodou je to, že zde odpadá nutnost algoritmizace úlohy. Jediné algoritmy, které se řeší jsou algoritmy tréninku a nastavení struktury neuronové sítě [25; 27].

Syntetické neurony slouží k vyhodnocení informací, které jsou přenášeny pomocí umělých synaptických spojení, která se nazývají jako tzv. váhové funkce. Váhová funkce je matematická funkce, která má tu schopnost, že se v průběhu optimalizačního vývoje může měnit. Nemá tudíž striktně nastavenou architekturu. Tyto funkce a jejich strukturu jsme schopni měnit tak, aby přenášená informace, a tím i výstup neuronové sítě byl co možná nejkorektnější vůči vlastnostem trénovací množiny. Pro posouzení správnosti výsledků z neuronové sítě využíváme tzv. ztrátovou funkci. Počítá se na základě reálného výstupu neuronové sítě a očekávaných výsledků [25; 27].

Speciálním typem neuronových sítí jsou konvoluční neuronové sítě (CNN – Convolutional Neural Networks) skládající se z vrstev, které provádějí 2-D konvoluci vstupních dat s naučenými filtry. Architektura CNN je tvořena tzv. hlubokými neuronovými sítěmi (deep networks), které v oblasti klasifikace dosahují vysoké přesnosti, neboť se jedná o tzv. metodu deep learning. Nejčastěji se konvoluční neuronové sítě využívají pro zpracování 2D dat, tedy obrazových záznamů. V takovém případě bývá navržená síť zakončena vrstvami pro přiřazení klasifikační třídy vstupních objektů [28; 29].

Výstup neuronu je vyjádřen jako


$$Y = \operatorname{sgn} \left(\sum_{i=1}^n w_i \cdot x_i - \vartheta \right) \quad (1)$$

kde:

w_i ...je váha vstupu i ,

x_i ...je hodnota vstupu i (příznaky z příznakového vektoru),

ϑ ...je vnitřní potenciál neuronu.



Obrázek 20: Model neuronu, převzato z [27]

4 Metody pro detekci a kvantifikaci retinálních lézí

Tato kapitola pojednává o metodách využívajících se pro detekci a kvantifikaci retinálních lézí a byla vypracována jako rešeršní část diplomové práce. Tomuto tématu se věnuje značné množství odborných publikací či článků, ale je důležité si uvědomit, že retinální léze mohou vznikat jak u retinopatie nedonošených, tak u diabetické retinopatie. V kontextu diplomové práce se však zaměřuji pouze na retinální léze spojené s retinopatií nedonošených.

Retinální léze, které mají charakteristický kruhový tvar a jsou vyplněny krví, jsou jedním z nejčastějších retinálních nálezů u předčasně narozených dětí, které mohou ohrozit jejich zrak. V klinické oftalmologii se oblast sítnice běžně vyšetřuje ze snímků sítnice pouhým okem. V takovém případě se však jedná o subjektivní hodnocení, které může být do jisté míry nepřesné. Stále častěji se však využívá tzv. vzdálená diagnostika prostřednictvím telemedicíny, což zlepšilo jako přístup ke screeningu, tak objektivitu v diagnostice. Objektivní posouzení obrazových záznamů sítnice hraje důležitou roli pro klinické hodnocení a plánování léčby, a právě z toho důvodu se začaly vyvíjet a rozšiřovat metody využívající umělou inteligenci, neboť dosahují velké přesnosti [30; 38].

Při výběru odborných publikací bylo použito strukturované hledání v různých internetových databázích jako je např. Web of Science, IEEE, PubMed, Scopus či Google Scholar. Vzhledem k tomu, že bylo potřeba hledat pouze retinální léze vzniklé v důsledku ROP, byl výsledný počet nalezených článků značně omezený. Z toho důvodu zde budou uvedeny i články, které se zabývají i detekcí ROP jako celku. Na základě abstraktů a klíčových slov bylo vybráno 10 článků, které jsou k tématu DP relevantní, a které jsou v rámci rešeršní části zpracovány. Z vybraných 10 článků se pouze dva věnují přímo detekci a kvantifikaci retinálních lézí (viz kapitola 4.2 a 4.10).

4.1 Historický vývoj umělé inteligence využívané v diagnostice retinopatie nedonošených

Umělá inteligence může kromě zlepšení účinnosti screeningu ROP vést rovněž k automatizované, kvantifikovatelné a objektivní diagnostice. Tato přehledová studie se zaměřuje na vývoj umělé inteligence pro automatizovanou diagnostiku ROP, neboť právě automatizovaná analýza obrazu a systémy hlubokého učení mají potenciál zlepšit efektivitu a přesnost diagnózy. Pro vývoj umělé inteligence pro automatizovanou diagnostiku snímků byl nezbytný rozvoj telemedicíny a digitálního zobrazování sítnice. Rozvoj těchto dvou oblastí vedl k vytvoření rozsáhlých databází sítnicových snímků s ROP, což byl zásadní krok pro vývoj umělé inteligence využívané v této oblasti [31].

Počítačové systémy pro diagnostiku ROP existují již více než deset let. Některé z prvních systému používaly ručně vytvořené míry dilatace a tortuozity pro stanovení objektivní míry závažnosti. Existuje více než tucet způsobů, jak algoritmicky měřit tortuozitu a dilataci, a nejstarší systémy se lišily v použitých rovnicích a metodách používaných k identifikaci retinálních cév. Všechny tyto způsoby byly založené na extrakci prvků. To znamená, že měli manuální nebo poloautomatický systém pro kvantifikaci dilatace a/nebo tortuozity na hodnotu, která měla určitou variabilní diagnostickou shodu s klinickou diagnózou ROP. Na rozdíl od následného strojového učení a technik hlubokého učení, počítač neprováděl žádné učení, všechny funkce a hraniční body byly určeny ručně (manuální systém). Teprve poloautomatické systémy, které obsahovaly požadavky lékaře na označení nebo výběr nálezu v rámci snímku, položily základy budoucího strojového učení [31].

První model strojového učení pro automatickou diagnostiku ROP byl představen v roce 2015. Na rozdíl od předchozích systému byl zde použit tzv. SVM (Support Vector Machine) klasifikátor, který využívá učení s učitelem, v rámci kterého, se model učí co možná nejlepšímu vztahu mezi získanými rysy a stanovenou diagnózou. Navzdory vysokému výkonu a přesnosti byl tento systém omezený manuálním trasováním a segmentací cév. Poté byly vyvinuty plně automatizované modely s využitím konvolučních neuronových sítí (CNN). Pomocí datových sad, jejichž snímky byly označeny řadou odborníků a které sloužily pro trénink sítě, bylo zjištěno, že takto získaný klasifikátor je pouze tak dobrý, jako jeho tréninková data. Metody strojového učení se dnes využívají jak pro diagnostiku ROP, tak pro klasifikaci závažnosti ROP [31].

4.2 Semisupervizorní learningový přístup pro automatickou segmentaci retinálních lézí pomocí tzv. SURF detektoru a lokálně adaptivní binarizace

Tento odborný článek představuje metodu zaměřenou na autonomní extrakci a klasifikaci retinálních lézí z retinálních záznamů. Jako vstupní data využívá 2 800 snímků sítnice od 80 pacientů s klinickými příznaky ROP pořízených systémem RetCam3. Všechny snímky byly pořízeny ve standardizovaném rozlišení 480x640 pixelů [30].

Navrhovaný algoritmus nejprve extrahuje ze vstupního RGB snímku zelenou složku pro usnadnění následného zpracování. Po tomto kroku lze zbytek algoritmu rozdělit do tří logických částí. První část je tvořena adaptivní binarizací a morfologickou operací. V této části je využito předpokladu, že oblasti retinálních lézí mají tmavší barvu než pozadí, a proto se tyto tmavé skvrny snaží jednoduše identifikovat převedením zeleného kanálu na binární obraz. Binární obraz má hodnoty pixelů buď 1 nebo 0 podle toho, zda je intenzita jejich zeleného kanálu pod nebo nad předem stanovenou prahovou hodnotou. Prahová hodnota zde byla určena pomocí lokální prahové adaptivní binarizace, která je v MATLABu dostupná využitím funkce *adaptthresh()*, která vypočítá lokálně adaptivní práh na základě průměrné intenzity okolí každého pixelu. u které je potřeba definovat dva parametry. První parametr určuje, které pixely jsou považovány za popředí, kdežto druhý parametr specifikuje statistiku použitou pro výpočet místního prahu. Velikost okolí se vypočítá jako:

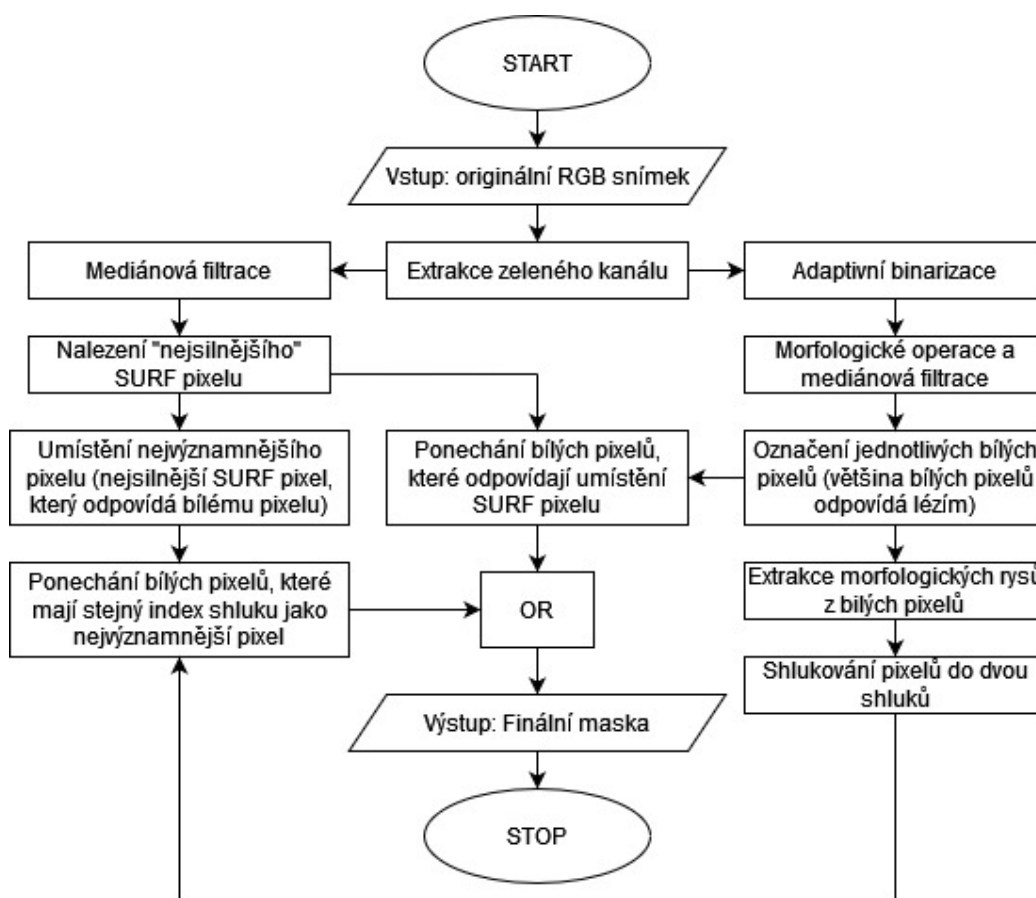
$$velikost\ okolí = 2 \cdot floor\left(\frac{size(I)}{16}\right) + 1, \quad (2)$$

kde:

I...je vstupní obraz (tedy zelená složka).

Po procesu adaptivní binarizace jsou součástí výstupního obrazu i retinální cévy, které nejsou oblastmi zájmu této studie. Z toho důvodu se provádějí některé morfologické operace, konkrétně mediánová filtrace, vyplnění děr a eroze. Druhá část algoritmu je tvořena SURF (Speed Up Robust Feature) detektorem, který slouží jako lokální detektor a deskriptor vlastností vstupního obrazu. Aby tento detektor detekoval jen tmavé pixely, které jsou oblastmi zájmu, je potřeba před jeho implementací provést další filtraci. Jakmile dostaneme výsledek porovnáme jej s výsledkem adaptivní binarizace. Konceptně tedy bereme průsečík mezi výsledky získanými SURF detektorem a výsledky adaptivní binarizace, neboť tento průsečík představuje oblast lézí detekovanými oběma metodami. Třetí a poslední částí algoritmu je semisupervizorní identifikace nejednoznačných oblastí lézí, tj. ne všechny pixely průsečíku doopravdy představují pixely lézí. K identifikaci těchto pixelů se v rámci této

práce využívá tzv. učení s částečným dohledem, které kombinuje supervizorní a neřízené strojové učení. Nejprve jsou pixely seskupeny do dvou skupin na základě jejich morfologických vlastností (excentricita, ekvivalentní průměr, pevnost, obvod plochy, kruhovitost a poměr vedlejší a hlavní osy) pomocí známého k-means algoritmu. Z výsledku k-means algoritmu však nevíme, který shluk regionů odpovídá lézím, a proto přichází koncept semisupervizorního učení. Zde je potřeba definovat tzv. nejvýznamnější pixel, který odpovídá „nejsilnějšímu“ SURF pixelu. Jakmile je tento pixel definován, můžeme získat jeho umístění a index shluku. Zcela logicky bude shlukový index nejvýznamnějšího pixelu odpovídat oblastem lézí. Pro vytvoření výsledného obrazu jsou zachovány pouze ty oblasti, které mají stejný index shluku jako tento nejvýznamnější pixel. Celý postup popsané metody je znázorněn níže (viz Obrázek 21) [30].




Obrázek 21: Vývojový diagram výše popsané metody (upraveno podle [30])

4.3 Využití rámce hlubokého učení pro detekci tzv. plus forem na retinálních snímcích předčasně narozených dětí

Hlavním cílem této odborné studie je vyvinout diagnostickou metodu, která dokáže rozlišit mezi obrazy sítnice s tzv. plus formami onemocnění ROP a zdravým kojencem (viz Obrázek 22). Přítomnost plus forem, které jsou klinicky diagnostikovány identifikací určitých morfologických změn retinálních cév (např. abnormální tortuozita či dilatace), představuje zásadní milník pro zahájení léčby. Tato práce využívá plně konvoluční architekturu hlubokého učení (tedy CNN) pro dosažení požadovaného cíle. Pro trénování sítě je použita technika učení s učitelem. Testování navrhované metodologie bylo

provedeno na souboru 289 snímků sítnice kojenců (89 s ROP a 200 zdravých) s rozlišením 1600 x 1200 pixelů. Všechny snímky byly pořízeny systémem RetCam3 [32].



Obrázek 22: Znárodnění normální zdravé sítnice (vlevo) a sítnice postižené plus formou onemocnění ROP (vpravo) [32]

Nově navrhovaná metoda pro detekci a kvantifikaci segmentů klikatých cév, které jsou signaturou plus forem onemocnění, může vést k časné diagnostice ROP u nedonošených dětí. Navržený diagnostický postup přímo označí klikaté segmenty pomocí CNN a poté následuje jejich kvantifikace spočítáním počtu takto označených segmentů [32].

Navrhovaná architektura sítě se skládá ze 33 konvolučních vrstev s filtry s proměnnou velikostí, aktivačními funkcemi, normalizací a zbytkovými vrstvami. Úlohou konvolučních vrstev je extrahovat mapy příznaků ze snímků sítnice pomocí detektorů příznaků (tzv. filter kernels). Mapa příznaků konvoluční vrstvy je vyhodnocena jako:

$$Y_K^i = f(W_K^i * Y_{K-1}^i), \quad (3)$$

kde $f()$ představuje aktivační funkci, W je velikost jádra filtru a $*$ označuje operaci konvoluce. Sít využívá děravou aktivační funkci, známou pod zkratkou ReLU (Rectified Linear Unit), ve všech vrstvách, neboť zabraňuje saturaci kladných a záporných vstupů. Pro vstup je funkce ReLU definována jako:

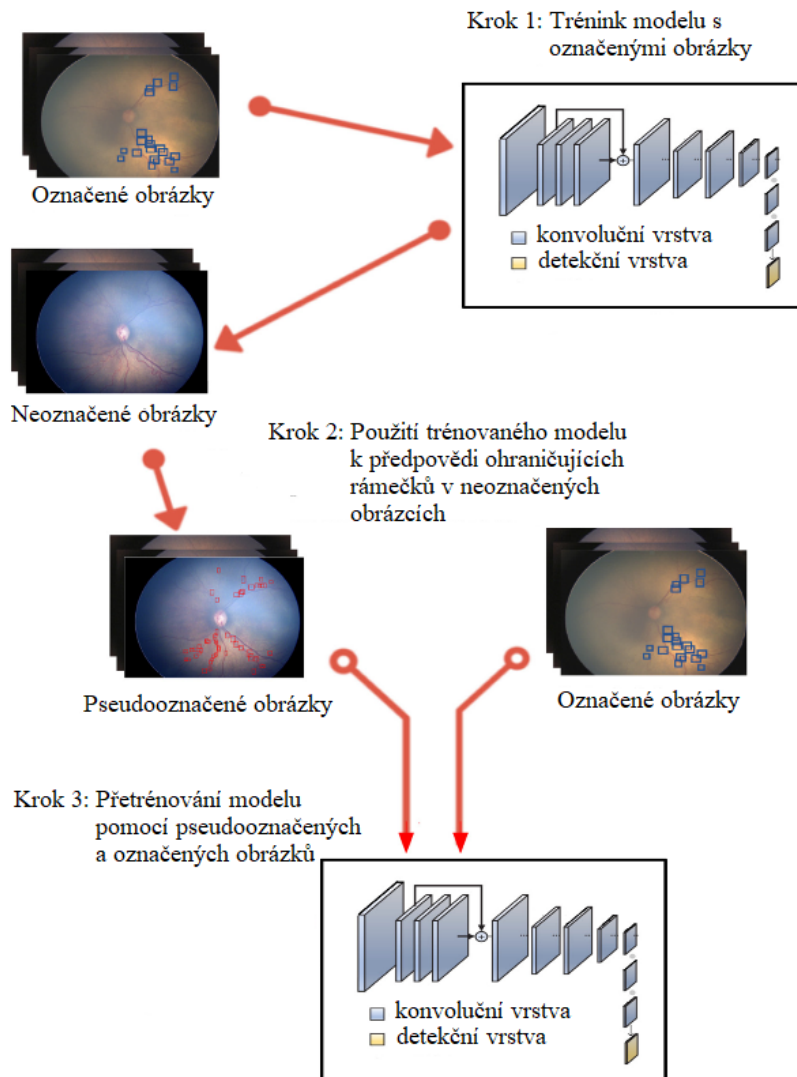
$$f(x_i) = \begin{cases} x_i, & \text{pokud } x_i \geq 0 \\ \alpha x_i, & \text{pokud } x_i < 0 \end{cases} \quad (4)$$

Záporný koeficient sklonu α je nastaven na hodnotu 0,1. Redukce rozměrů map je v každé fázi řízena změnou kroku síťových vrstev. Krok řídí posun jádra filtru při provádění konvoluce ve vrstvách. Sít využívá zbytkové vrstvy, které pomáhají při generování vylepšených vlastností přidáním prvků z předchozích vrstev pomocí připojení k naučenému zbytku. Normalizace je provedena za účelem snížení rozptylu mezi po sobě jdoucími vrstvami a urychluje tréninkový proces [32].

Sít rozdělí daný vstupní obraz na 52 x 52 buněk mřížky a předpovídá jejich ohraničení rámečky. Každý rámeček je dán pěti atributy (t_0, x, y, w a h). První atribut představuje míru spolehlivosti, která poukazuje na existenci abnormálního segmentu cévy uvnitř rámečku. Spolehlivost je určena jako součin pravděpodobností, že buňka mřížky obsahuje abnormální segment. Souřadnice x, y představují střed ohraničujícího rámečku, jehož výška a šířky jsou reprezentovány jako w a h . Výška a šířka jsou nastaveny pomocí předem definovaných priorit, nazývaných jako kotevní rámečky. Tyto rámečky jsou nastaveny na základě velikostí objektů v trénovacích datech. Během detekce jsou kotevní rámečky rozmístěny po obraze a poté síť předpovídá jejich posun. Výstup sítě je určitý počet ohraničujících rámečků, které ohraničují segmenty klikatých cév přítomných na snímku. Dále se na

každém snímku spočítá počet těchto rámečků a výsledné číslo je použito pro následnou diagnózu plus forem onemocnění ROP [32].

Pro síťový trénink je použit tzv. transferový přístup učení, který spočívá v inicializaci prvních 24 vrstev sítě pomocí předem trénovaných dat sítě Darknet-53 a v inicializaci hlavních devíti konvolučních vrstev pomocí náhodných dat. To znamená, že síť je nejprve trénována pomocí obrázků s ručně nakreslenými ohraničujícími rámečky přes abnormální segmenty cév. Trénovaná síť se poté použije k předpovědi ohraničujících rámečků nad abnormálními segmenty neznámého obrazu. Obrázky s nově předpovězenými rámečky jsou spolu s původně označenými obrázky použity k opětovnému trénování. Princip tréninku je znázorněn níže (Obrázek 23) [32].



Obrázek 23: Postup při tréninku dat (upraveno podle [32])

4.4 Vývoj automatizované vícerozměrné platformy využívající hlubokého učení snímků sítnice pro screening retinopatie nedonošených

Cílem této diagnostické studie je vývoj multidimenzionální, automatizované platformy hlubokého učení pro screening ROP, která by dokázala splnit diagnostická kritéria potřebná ke správné, ale především včasné diagnóze. Diagnostická kritéria byla stanovena skupinou oftalmologů. Celkem bylo použito 52 249 snímků sítnice pořízených sítnicovými kamerami RetCam2 či RetCam3. Tyto snímky

byly náhodně rozděleny do tréninkové, validační či testovací sady v poměru 75:10:15. Rovněž byly vyvinuty čtyři nezávislé hlavní klasifikátory, a to kvalita obrazu, jakékoli stádium ROP, nitrooční krvácení (retinální léze) a plus formy onemocnění, a jeden pomocný parametr (zadní část sítnice) [33].

Oblast zadní části sítnice musela být definována z důvodu správné identifikace plus forem. V této studii byla zadní část sítnice definována jako kruhová oblast se středem v optickém disku s poloměrem 3x větším, než je průměr optického disku. Jakákoli část snímku v této předem definované oblasti byla klasifikována jako zadní pól [33].

Co se týče postupu vyhodnocení jednotlivých snímků, bylo nejprve potřeba vyhodnotit kvalitu každého snímku. Pokud byla kvalita určena jako špatná, bylo dáno doporučení k přefotografování. Pokud byl snímek označen jako kvalitní, mohl vstoupit do hlavního procesu. Hlavní strukturou systému je tzv. multilabel klasifikace, která pracuje s přesvědčením, že se na jednom snímku dá nalézt více znaků současně. Tento klasifikační systém byl implementován pomocí více nezávislých klasifikátorů založených na binární relevanci (zanedbávání závislosti na třídě). S ohledem na modelovaný soubor byla každá klasifikační úloha implementována pomocí sady různých neuronových sítí. Neuronová síť má více vstupů a jeden výstup [33].

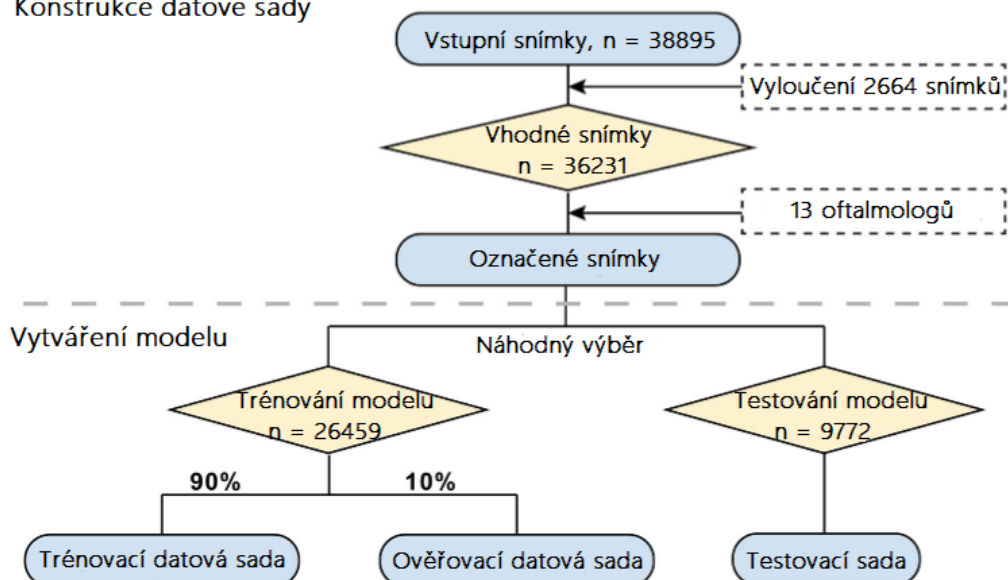
Závěrem lze říct, že vyvinutá platforma je schopna identifikovat a klasifikovat multidimenzionální patologické léze na snímcích sítnice, a právě proto může být užitečná při rutinním screeningu ROP ve všeobecných a dětských nemocnicích. Na druhou stranu, testovací sada obsahovala i malé množství chybně klasifikovaných snímků. Nejčastějším důvodem chybné klasifikace byl špatný kontrast pořízeného snímku sítnice [33].

4.5 Automatizovaná identifikace retinopatie nedonošených pomocí obrazového hlubokého učení

Tato studie byla provedena za účelem vývoje robustního inteligentního systému založeného na hlubokém učení, který automaticky klasifikuje závažnost ROP ze snímku očního pozadí a umožňuje tak automatizovanou diagnostiku. V rámci studie bylo použito celkem 38 895 snímků, které byly získány pomocí širokoúhlého zobrazovacího zařízení (RetCam, Clarity Medical Systems, Pleasanton) a jejich rozlišení je 640x480 pixelů. Pro samotnou klasifikaci a identifikaci snímků byla využita 101vrstvá konvoluční neuronová síť (ResNet) a rychlejší konvoluční neuronová síť založena na regionech (Faster-RCNN), která přímo zvýrazňuje oblasti lézí, neboť se jedná o síť určenou právě pro detekci objektů. K trénování a optimalizaci algoritmů byla použita metoda 10násobné křížové validace [34].

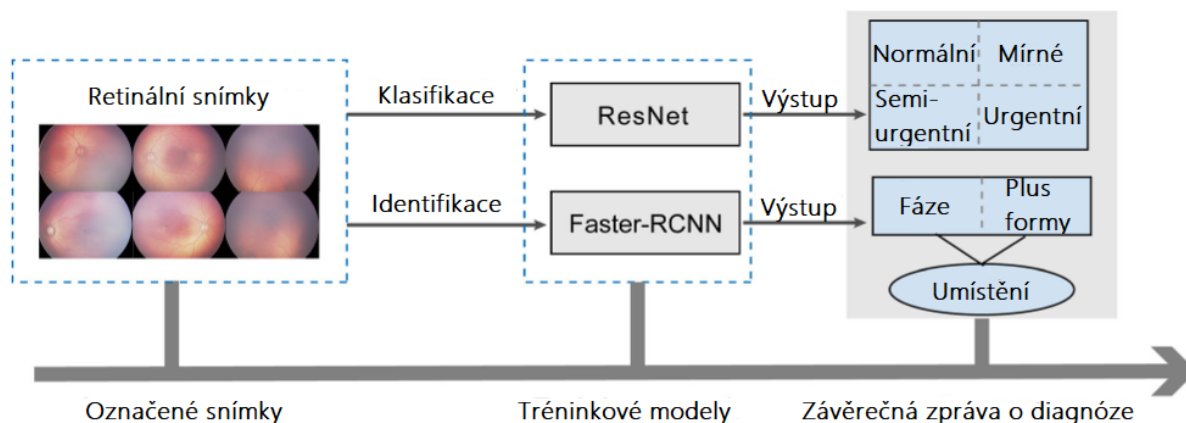
Celkový experimentální design a proces výběru datového souboru je znázorněn níže (Obrázek 24). Z celkového počtu použitých snímků jich bylo celkem 2 664 vyloučeno v důsledku špatné kvality obrazu, zobrazovacích artefaktů či nezaostření pořízeného skenu. Zbývajících 36 231 snímků bylo zahrnuto do aktuální studie pro sestavení inteligentního systému. Každý snímek byl poté označen dvěma štítky (Obrázek 25). První štítek, tzv. klasifikační, představoval jeden ze čtyř stupňů závažnosti ROP podle požadavků klinické léčby (normální, mírné, semiurgentní a urgentní). Druhý štítek, označovaný jako identifikační, byl přidán k označení ROP stádií (fibrovaskulární postižení, subtotální odchlípení sítnice, totální odchlípení sítnice či dilatace a tortuozita retinálních cév). Kromě toho byla oblast lézí označena odborníky pomocí rámečku [34].

Konstrukce datové sady



Obrázek 24: Design a proces výběru datového souboru, upraveno podle [34]

Před samotným učením bylo potřeba snímky předzpracovat pomocí přidání náhodného šumu a úpravy jasu. Snímky byly poté zmenšeny na standardní rozlišení 224x224 pixelů, aby odpovídaly očekávané vstupní velikosti pro trénování algoritmů. Získaný zpracovaný datový soubor byl poté náhodně rozdělen na tréninkový soubor, který byl použit k vývoji modelu učení, a testovací datový soubor použitý k vyhodnocení modelu. Během tréninkového procesu byla k vyhodnocení a optimalizaci modelu použita konvenční metoda 10násobné křížové validace, která spočívá v rozdělení vzorku do 10 dílčích vzorků stejné velikosti. Jako trénovací sada bylo vybráno devět vzorků a zbylý jeden vzorek slouží jako ověřovací sada. Pro vývoj algoritmu byly využity dvě CNN sítě, které se skládají z několika konvolučních vrstev. První, 101vrstvá ResNet klasifikační síť, která byla předem natrénována v databázi ImageNet, byla přetrénována na zde použité datové sadě pomocí tzv. přenosového učení, které algoritmu umožňuje aplikaci znalostí získaných z jiných datových sad na novou datovou sadu. Druhá, Faster-RCNN síť, slouží k rozpoznání a klasifikaci každého objektu v obraze a rovněž pro umístění každého objektu do rámečku. Kombinací těchto dvou CNN sítí byla získána klasifikace závažnosti ROP stejně jako diagnóza stádia ROP a přítomnost plus forem onemocnění [34].




Obrázek 25: Proces klasifikace a identifikace, upraveno podle [34]

4.6 Automatizovaná detekce a klasifikace časných stádií ROP pomocí hluboké konvoluční neuronové sítě

Hlavním úkolem této studie je navrhnout systém, který dokáže přesně odlišit raná stádia ROP a potenciálně tak pomoci oftalmologům v jeho klasifikaci. V rámci této studie bylo použito celkem 11 372 snímků sítnice, které byly rozděleny na 10 235 snímků (90 %) pro trénink a 1137 snímků (10 %) pro ověření a doladění. Všechny snímky byly pořízeny systémem RetCam s rozlišením 1600x1200 pixelů a databáze rovněž obsahovala základní demografické údaje pacientů (pohlaví, gestační věk a porodní hmotnost). Byla zde implementována hluboká CNN pro klasifikaci snímků na základě závažnosti ROP. Model byl trénován pomocí 5násobné křížové validace [35].

Pro klasifikaci a extrakci relevantních údajů byly snímky vloženy do neuronové sítě. Velikost původních RGB snímků byla 1600x1200, avšak tato velikost byla změněna na 224x224 pixelů pro zajištění zvětšení měřítka. Architektura CNN byla tvořena pěti konvolučními vrstvami, včetně vstupní vrstvy, která specifikuje šířku, výšku a počet kanálů, a čtyři skryté vrstvy. Výstupy z konvolučních vrstev byly zploštěny do vektoru a připojeny k plně propojeným vrstvám (FC). Finální výstupní vrstva, tzv. softmax vrstva, byla navržena pro klasifikaci stupňů ROP [35].

Každá konvoluční vrstva obsahuje 5x5 konvolucí a po normalizaci je aplikována aktivační funkce (ReLU), která zlepšuje tok informací a snižuje překrytí modelu. Každá vrstva sítě vypočítává vážený součet všech neuronových výstupů předchozích vrstev, čímž vytvoří mapu příznaků, a poté následuje nelineární aktivace ReLU. Každá aktivace vrstvy byla vložena do další vrstvy v síti, která prováděla stejné výpočty, dokud nebylo možné vstupní obraz přesně klasifikovat. Po každé konvoluční vrstvě byla zavedena maximální sdružovací vrstva s velikostí okna 2x2 pixely, která měla za úkol zmenšovat datové rozměry každého shluku neuronů předchozí síťové vrstvy. Celková architektura použité CNN je znázorněna níže (Obrázek 26) [35].



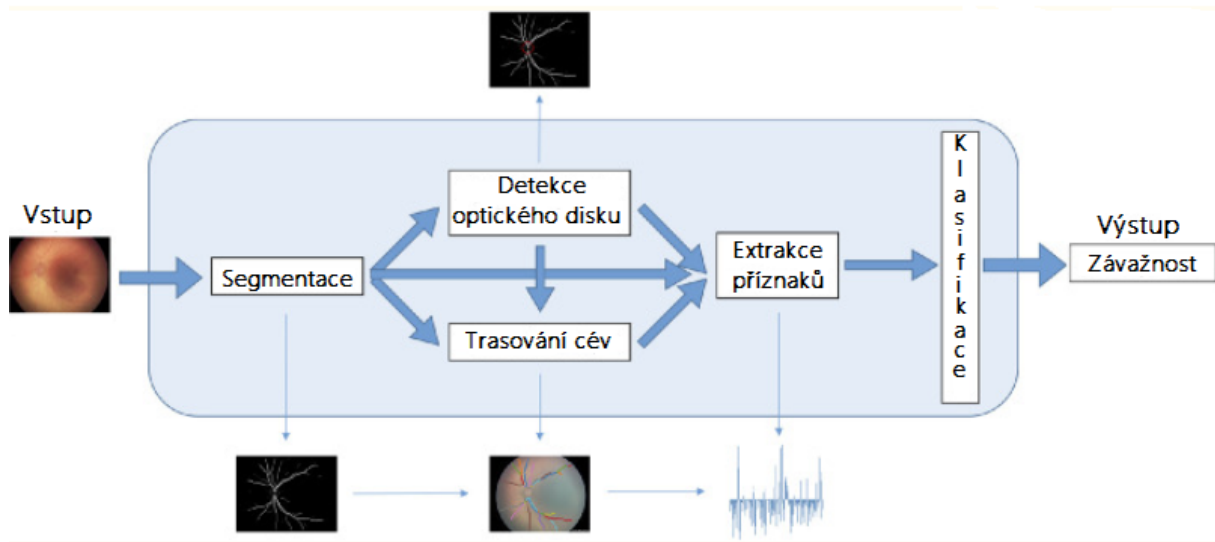
Obrázek 26: Architektura použité hluboké neuronové sítě, upraveno podle [35]

Závěrem byl navrhovaný model otestován na 244 snímcích sítnice, které byly předem označeny a klasifikovány zkušenými oftalmology. Z celkového počtu bylo 15 snímků, tedy 6,15 %, špatně zařazeno. Tato data tedy naznačují že navrhovaný model dosahuje vysoké přesnosti v diagnostice ROP [35].

4.7 Identifikace ROP s využitím konvoluční neuronové sítě s kombinovaným přístupem a extrakcí funkcí

Tato studie se zaměřuje především na identifikaci plus forem ROP, které jsou definovány jako abnormální tortuozita a dilatace retinálních cév. Cílem bylo vytvořit veřejně dostupný kanál I-ROP ASSIST kombinující automatickou segmentaci retinálních cév, trasování, extrakci rysů a klasifikaci, který by pomáhal při diagnostice onemocnění ze snímků sítnice. Byly vyvinuty dva datové soubory obsahující 100 a 5 512 retinálních snímků, které byly pořízeny pomocí širokoúhlé fundus kamery RetCam. Velká datová sada obsahující 5 512 snímků byla použita pro trénink a validaci pomocí přístupu křížové validace. Menší datový soubor obsahoval odborníky klasifikované snímky. Celkový postup řešení byl rozdělen do dvou hlavních částí. V první části byly retinální cévy nejprve segmentovány a následně byly detekovány osy těchto cév. Ve druhé části byly extrahovány funkce relevantní pro ROP (měření tortuozity a dilatace), které byly poté použity v klasifikátorech k posouzení závažnosti onemocnění [36].

Postup diagnostiky je rozdělen do pěti kroků (Obrázek 27). Vstupní obraz sítnice nejprve prochází procesem segmentace cév a poté je detekován střed optického disku. Ze segmentovaných snímků a středů optických disků jsou extrahovány informace o cévním řečišti (detekce osy cév). Pomocí výstupů z předchozích kroků jsou extrahovány rysy sítnice, které jsou použity pro následnou klasifikaci, ve které se vytvoří skóre závažnosti [36].



Obrázek 27: Postup navrhovaného systému [36]

Navrhovaný systém využívá pro segmentaci předem trénovanou architekturu U-Net CNN, která byla trénována na 200 ručně segmentovaných snímcích s využitím ztrátové zkřížené entropie. Trénovaná síť segmentuje vstupní obraz extrahováním všech překrývajících se polí s 8pixelovým krokem, který má za následek zprůměrování překrývajících se částí a vytvoření výstupního obrazu s hodnotami pixelů v rozsahu od 0 do 1. Detekce optického disku je použita pro sledování cév a extrakci příznaků a je opět zajištěna automatickým detektorem využívajícím CNN. Na výstupní vysegmentovaný obraz je před jeho odesláním do extrakčního modulu aplikován práh pomocí Otsu metody, která využívá histogram obrazu a minimalizuje rozdíly v rámci třídy. Následná aplikace strojového učení vyžaduje reprezentaci snímků pomocí informativních funkcí, v tomto případě se tedy jedná o cévní dilataci a tortuozitu. V této části systému tedy dochází k extrakci příznaků a k vytvoření příznakového vektoru o velikosti 143. V rámci klasifikace byly použity tři různé klasifikátory, a to logická regrese, SVM (Support Vector Machine) a neuronová síť, která je ve formě plně propojeného vícevrstvého perceptronu [36].

Nevýhodou výše uvedeného systému je to, že vstupní snímky musí mít rozlišení 480x640 pixelů. V případě jiného rozlišení dojde k jeho úpravě, a to může výrazně ovlivnit kvalitu snímku a celkový výsledek [36].

4.8 Automatizovaná detekce retinopatie nedonošených prostřednictvím hluboké sítě

Tato studie využívá pro automatizovanou detekci ROP hlubokou konvoluční neuronovou síť (DCNN). Mezi nejdůležitější faktory této sítě patří její hloubka, šířka a mohutnost. Kromě těchto faktorů je nutné správně definovat tzv. mechanismus pozornosti, který zaměří pozornost sítě na důležité funkce a ty nepotřebné potlačí. V této studii je mechanismus pozornosti zaměřen na patologické struktury ROP, které jsou lokalizovány pomocí diskriminační techniky známé jako gradientní vážené mapování (Grad-CAM). K trénování sítě byla použita sada snímků očního pozadí získaných pomocí RetCam2 či RetCam3. Data jsou opět označena zkušenými oftalmology [37].

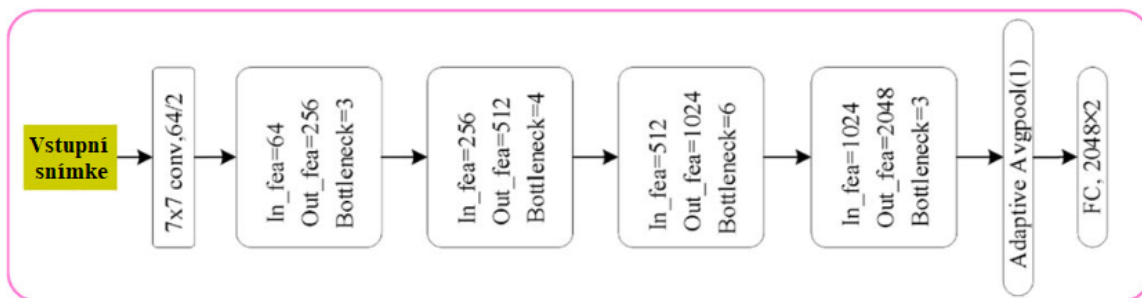
Navrhovaná metoda se skládá z několika částí. První částí je základní architektura pro klasifikaci, která je založena na tzv. zbytkovém učení. Schopnost reprezentace prvků DCNN lze zvýšit vrstvením bloků. Obvyčejný blok je definován jako:

$$y = F(x, W), \quad (5)$$

kde x a y označují vstup a výstup bloku, $F(\cdot)$ označuje základní mapovací funkci, která je naučena sadou parametrů W těchto naskládaných vrstev. Je důležité si uvědomit, že s rostoucí hloubkou se síť obtížněji trénuje. Z toho důvodu je zde použit zbytkový rámeček učení, který je definován jako:

$$y = F(x, W) + x. \quad (6)$$

Rámeček zbytkového učení lze implementovat prostřednictvím spojení, které provádí sčítání po prvcích na vstupu a výstupu. V této studii je jako základní architektura použita struktura ResNet50, jejíž struktura je uvedena níže (Obrázek 28). Ve druhé části je implementován modul CASA (Channel and Spatial Attention), který slouží jak pro zlepšení reprezentace funkcí DCNN, tak pro definování mechanismu pozornosti. Pomocí CASA modulu je získána tzv. mapa pozornosti (podmodul CA generuje 1D mapu, čímž získává mapu funkcí; podmodul SA generuje 2D mapu pozornosti na základě funkcí získaných podmodulem CA). Architektura sítě je integrována s CASA modulem za účelem extrakce diskriminačních znaků souvisejících s ROP. Poté jsou získané znaky zpracovány technikou Grad-CAM pro vizualizaci naučených vlastností a lokalizaci patologických struktur [37].



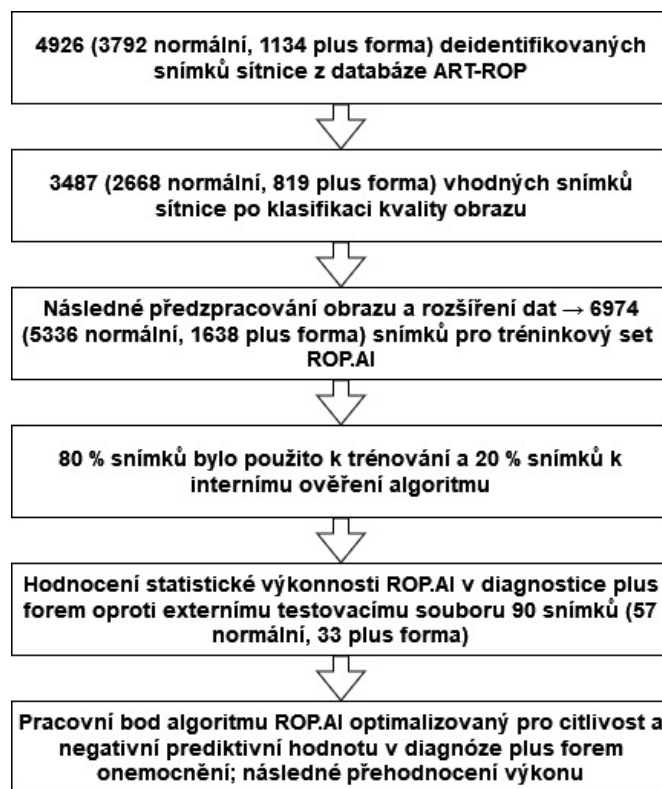
Obrázek 28: Struktura použitého modelu ResNet50, kde In_fea a Out_fea označují číslo kanálů vstupních a výstupních funkcí a FC označuje plně připojenou vrstvu [37]

4.9 Algoritmus hlubokého učení pro automatickou diagnostiku ROP

Účelem zmíněné metody je popis počátečního vývoje algoritmu hlubokého učení (ROP.AI), který slouží pro automatickou diagnostiku ROP na snímcích sítnice. Algoritmus ROP.AI byl trénován pomocí 6 974 snímků a jeho výkon byl hodnocen v rámci externího souboru 90 snímků (57 snímků bez přítomnosti ROP, 33 snímků s ROP). Všechny použité snímky sítnice byly pořízeny pomocí komerčně dostupné kamery (RetCam, Pleasanton) při standardním zorném poli 130° a rozlišení 640x480 pixelů. Pomocí algoritmu byly snímky klasifikovány buď jako „normální sítnice“ nebo jako „plus forma“ [38].

Pro zpracování bylo původně přijato 4 926 snímků, které byly ručně klasifikovány podle kvality snímku. Na základě kvality bylo 1 439 vyřazeno, což znamená, že do předběžného zpracování a augmentace dat bylo zahrnuto pouze 3 487 snímků. Předzpracování sestávalo z oříznutí textových anotací a rozšíření dat pomocí horizontálního převrácení pro zdvojnásobení počtu snímků použitých pro finální trénovací sadu. Snímky byly poté nahrány pomocí webového prohlížeče Safari na cloudovou platformu pro hluboké učení konvoluční neuronové sítě (CNN). CNN fungují tak, že se učí a zároveň využívají řadu filtrů, které zdůrazňují vlastnosti obrazu, které jsou relevantní pro daný úkol. Byla zde použita odstupňovaná klasifikace, která snímky normálního pozadí a snímky s plus formou nahrává do samostatných přihrádek. K samotnému tréninku byla využita ztrátová zkřížená entropie a

výstupní softmax vrstva byla použita k vytvoření pravděpodobnostních výstupů. Algoritmus ROP.AI tedy vrací hodnoty mezi 0 a 1 s tím, že ve výchozím nastavení se používá práh pracovního bodu 0,5. To znamená, že hodnoty nad tímto bodem indikují plus formu onemocnění. Statistická výkonnost klasifikátoru byla měřena výpočtem senzitivity, specifity, přesnosti, pozitivní prediktivní hodnoty a negativní prediktivní hodnoty. Celkový postup výběru dat a následné zpracování je uvedeno níže (Obrázek 29) [38].



Obrázek 29: Vývojový diagram modelu [38]

Závěrem lze tedy říct, že ROP.AI je algoritmus hlubokého učení, který je schopný automaticky diagnostikovat plus formy onemocnění ROP s vysokou citlivostí a negativní prediktivní hodnotou [38].

4.10 Hodnotící kritérium pro retinální krvácení u novorozenců založené na hlubokých konvolučních neuronových sítích

Hlavním cílem této studie bylo definovat nové kvantitativní hodnotící kritérium pro retinální krvácení objevující se u některých donošených novorozenců na základě výsledků segmentace hluboké konvoluční neuronové sítě (DCNN). Retinální krvácení se u novorozenců může objevovat v důsledku hypoxie, způsobu porodu či vyššího věku matky. Nejprve byla vytvořena datová sada o 1543 snímcích sítnice s rozlišením 3264x2448 pixelů. Všechny snímky byly pořízeny pomocí komerční kamery. Poté byla vyvinuta DCNN pro segmentaci retinálních lézí, retinálních cév a optických disků. Navržená DCNN byla rovněž použita pro lokalizaci makulární oblasti. Na základě poměru oblastí s krvácením k optickému disku a umístění těchto krvácení vzhledem k makulární oblasti bylo definováno nové kritérium pro klasifikaci stupně krvácení [39].

Z vytvořené databáze obsahuje pouze 600 snímků retinální krvácení. Tyto snímky byly rozděleny do tréninkových (500 snímků) a testovacích (100 snímků) datových sad. Pro správné natrénování sítě bylo veškeré krvácení ručně označeno pomocí dvou oftalmologů [39].

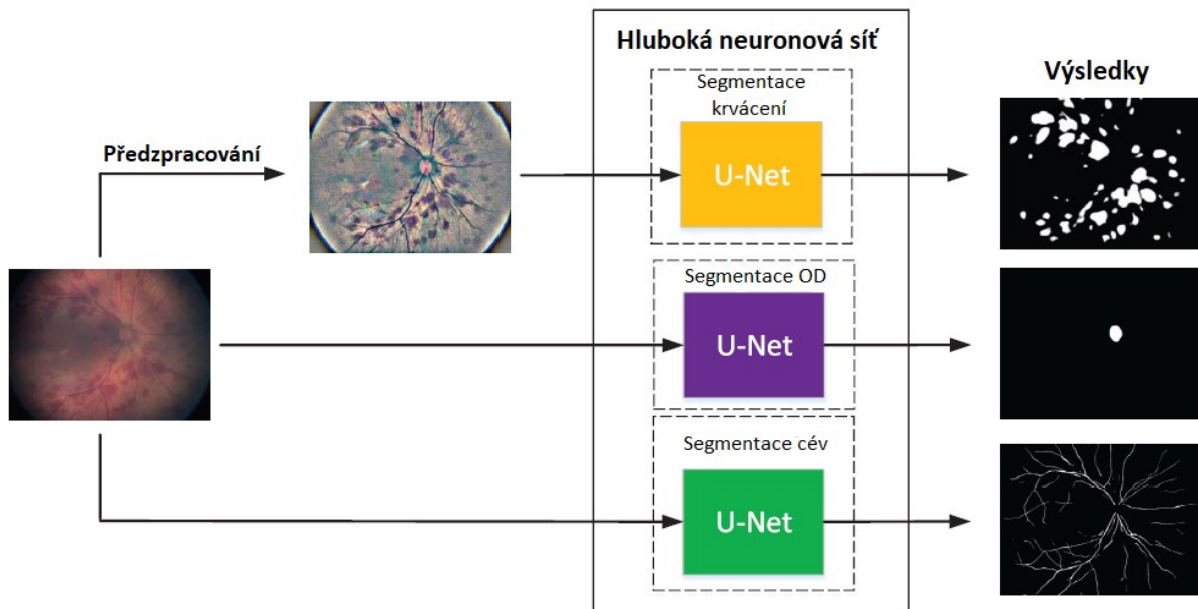
Navržená metoda využívá tři U-net sítě (viz Obrázek 30), každou pro segmentaci jiné struktury fundu: optický disk (OD), retinální cévy, retinální krvácení. Snímky, na kterých bylo zachyceno krvácení, byly předzpracovány pomocí Gaussova filtru. U-net je plně konvoluční neuronová síť, která je schopna kombinovat globální a lokální vlastnosti obrazu propojením odpovídajících vrstev kódovacích a dekódovacích cest. Na základě výsledků segmentace všech tří struktur bylo definované klasifikační kritérium pro hodnocení míry krvácení. Poměr R mezi plochou krvácení a optickým diskem byl použit k definování čtyř stupňů krvácení:

$$R = \frac{\text{celková plocha krvácení}}{\text{plocha optického disku}} \quad (7)$$

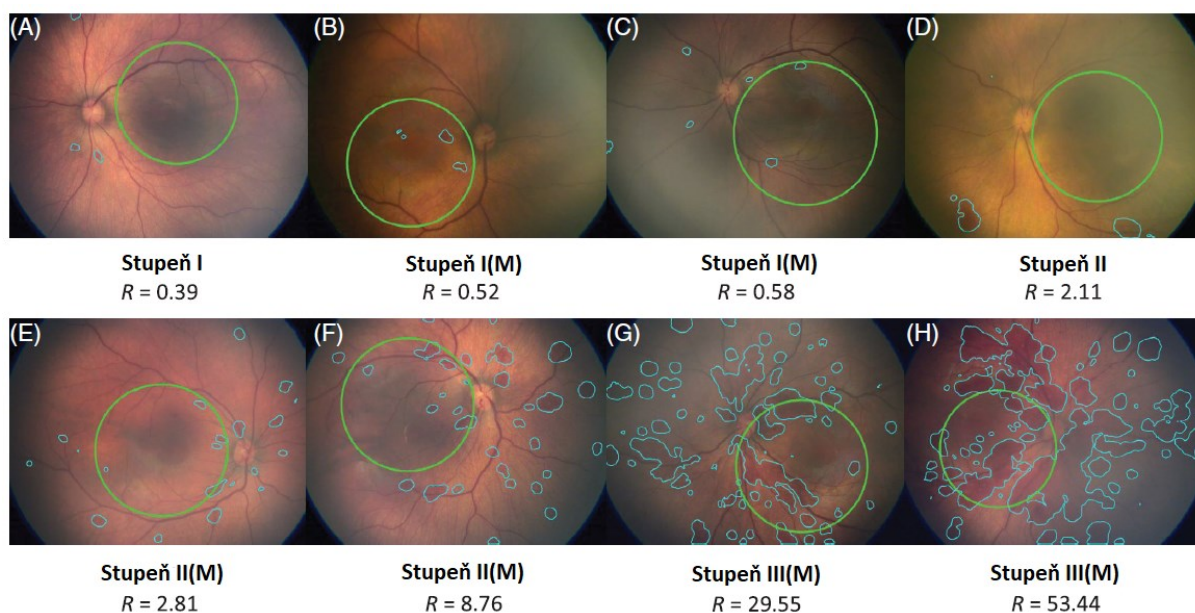
Definice čtyř stupňů krvácení jsou uvedeny níže (Tabulka 8). Ke každému stupni může být doplněno písmeno „M“, které značí krvácení i v makulární oblasti (viz Obrázek 31) [39].

Tabulka 8: Čtyři stupně krvácení podle velikosti R [39]

Poměr R	R = 0	0 < R ≤ 1	1 < R ≤ 10	R > 10
Stupeň krvácení	Zdravý	I	II	III



Obrázek 30: Přehled navrhovaných segmentačních sítí [39]



Obrázek 31: Reprezentativní příklady různých stupňů retinálního krvácení (zelené kruhy označují makulární oblast) [39]

Na základě navržené DCNN je možné s vysokou přesností segmentovat retinální krvácení, retinální cévy a dále optický disk. Výkon navrhované sítě a výsledky segmentace byly porovnány s výsledky segmentace založené na hlubokém učení u dospělých, neboť u novorozenců neexistují žádné předchozí metody segmentace. Navrhované klasifikační kritérium zohledňuje nejen oblast krvácení, ale také umístění vzhledem k makulární oblasti. Tím pádem poskytuje objektivnější a komplexnější hodnotící kritérium [39].

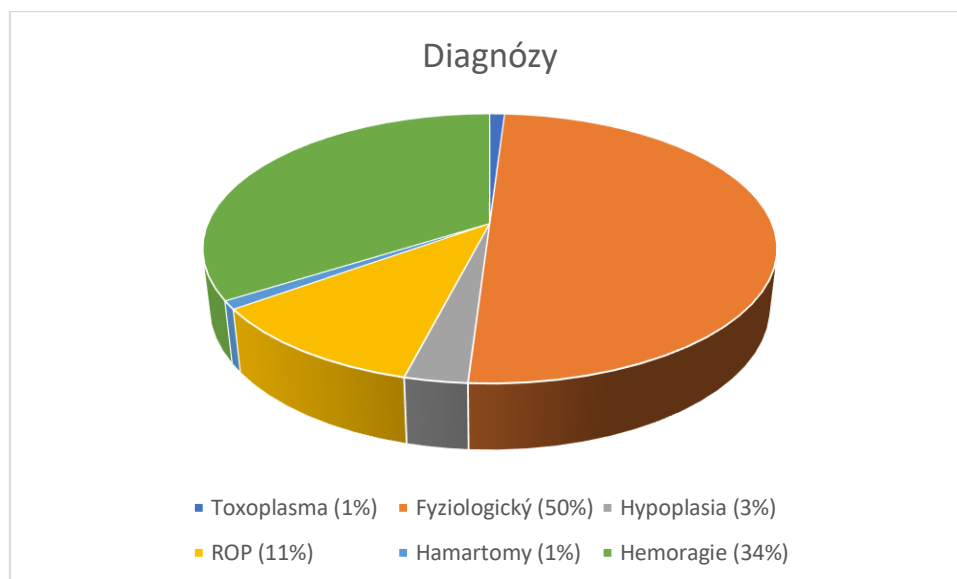
5 Charakteristika použitých obrazových dat

V rámci této práce byla využita obrazová data pořízená systémem RetCam3. Všechna data byla poskytnuta Oční klinikou Fakultní nemocnice Ostrava (FNO).


5.1 Data pořízená systémem RetCam3

Dataset snímků, pořízených RetCamem3 s rozlišením 640x480 pixelů, poskytnutý Oční klinikou FNO obsahuje celkem 2 793 snímků sítnice, které byly pořízeny od 80 předčasně narozených dětí. Screeningové vyšetření se u předčasně narozených dětí provádí za účelem zjištění přítomnosti onemocnění ROP. Při získávání snímků byl tedy zaznamenán jak gestační věk dítěte, tak i jeho porodní váha či pohlaví. Rovněž bylo důležité zachovat anonymitu každého vyšetřovaného jedince. Všechny tyto informace jsou součástí excelovské tabulky, která je v rámci databáze dostupná. Kromě těchto základních informací obsahuje tabulka i počet sérií neboli počet návštěv u lékaře, při kterých bylo provedeno screeningové vyšetření. Počet sérií a jednotlivý počet snímků v nich pořízených se u každého pacienta liší, neboť zdravotní stav každého jedince se s postupem času vyvíjí jinak. S počtem sérií souvisí i aktuální diagnostika po absolvovaném vyšetření. Mezi diagnózy, diagnostikované v rámci této databáze, patří hemoragie, hamartomy, ROP, hypoplasia či toxoplasma. Procentuální zastoupení a ukázky patologických snímků jsou vyobrazeny níže (viz Obrázek 32 a Obrázek 33). Je důležité upozornit na to, že ne všechny snímky této databáze obsahují patologii. Velký počet snímků je bez jakéhokoli nálezu, a tím pádem jsou chápány jako fyziologické [19].

V rámci této práce a navrženého algoritmu bylo nutné pracovat pouze se snímky obsahujícími retinální léze neboli hemoragie (krvácení). Z celkového počtu snímků se retinální léze objevují celkem na 835 snímcích pořízených od 26 pacientů. Je však důležité upozornit na to, že jen malé množství z těchto snímků má pro praktickou část této práce vypovídající hodnotu, co se týče kvality, neboť pořídit dostatečně kvalitní data od pacientů starých jen několik málo týdnů či dní je značně obtížné a náročné i pro zkušené odborníky. Ve výsledku bylo vybráno celkem 38 snímků, na kterých byl algoritmus testován [19].



Obrázek 32: Graf znázorňující procentuální zastoupení diagnostikovaných onemocnění



Obrázek 33: Příklady jednotlivých diagnóz

Jak již bylo zmíněno výše, onemocnění ROP postihuje především předčasně narozené děti, které se narodily před dosažením 31. gestačního týdne a jejichž porodní váha nepřesahuje 1500 g. Součástí databáze jsou však i snímky pacientů, kteří tyto parametry převyšují, neboť tyto parametry nepředstavují striktní hranici pro provedení samotného screeningu. Tabulka 9 znázorňuje procentuální zastoupení pacientů v rámci těchto dvou parametrů (gestační věk a porodní váha) [19].

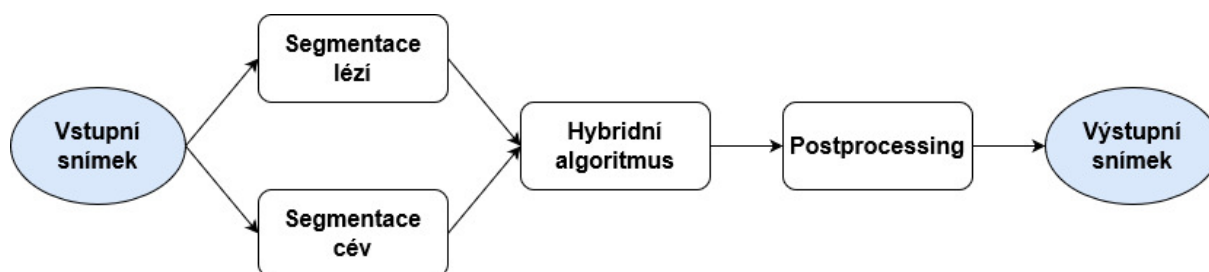
Tabulka 9: Procentuální zastoupení vyšetřovaných jedinců databáze Oční kliniky FNO v rámci dvou sledovaných parametrů

Sledovaný parametr	Rozmezí	Procentuální zastoupení
Gestační věk	24.-27. týden	14 %
	28.-31. týden	19 %
	32.-37. týden	34 %
	38.-41. týden	33 %
Porodní váha	méně než 1000 g	17 %
	1000-1499 g	24 %
	1500-1999 g	14 %
	2000-2499 g	10 %
	2500-2999 g	9 %
	3000-3499 g	11 %
	více než 3499 g	15 %

6 Návrh a realizace hybridního algoritmu

Hlavním cílem této diplomové práce je návrh hybridního algoritmu, s využitím již existujícího algoritmu pro segmentaci retinálních lézí, pro identifikaci a segmentaci retinálních lézí ze snímků poskytnutých Oční klinikou FNO.

Pod pojmem hybridní algoritmus se rozumí algoritmus, který kombinuje dva nebo více dalších algoritmů, které řeší stejný problém v rámci vstupní proměnné. V tomto případě byl hybridní algoritmus použit za účelem návrhu dostatečně kvalitního algoritmu určeného k segmentaci pouze a jen retinálních lézí. Navrhovaný algoritmus kombinuje celkem dva segmentační algoritmy. V rámci prvního algoritmu dochází k segmentaci lézí, avšak tento algoritmus v mnoha případech chybně segmentuje i části cévního řečiště. Z toho důvodu byl následně použit další segmentační algoritmus zaměřený na segmentaci retinálních cév. Po získání obou výstupů dochází k implementaci hybridního algoritmu, který je doplněn o následný postprocessing. Schéma navrhovaného hybridního algoritmu je znázorněno níže (Obrázek 34).



Obrázek 34: Blokové schéma navrhovaného algoritmu

6.1 Algoritmus pro segmentaci retinálních lézí

Základní princip tohoto algoritmu je částečně popsán již v rešeršní části této diplomové práce (konkrétně se jedná o kapitolu 4.2). Nyní však bude popsán důkladněji.

Jak již bylo zmíněno, celý principiální postup algoritmu je možné rozdělit na tři logické celky, a to na adaptivní binarizaci následovanou morfologickými operacemi, SURF detektorem a poslední část představuje semisupervizorní identifikaci (viz Obrázek 35). Každý celek je v následující části práce podrobně popsán a vysvětlen [30].



Obrázek 35: Postup při segmentaci retinálních lézí

6.1.1 Adaptivní binarizace následovaná morfologickými operacemi

Před samotnou implementací adaptivní binarizace je nutné si uvědomit jednu důležitou věc a to tu, že se retinální léze vyznačují tmavší intenzitou než pozadí. Abychom tuto skutečnost využili, a tedy i znásobili, je nutné extrahovat zelenou složku z původního RGB snímku, který obsahuje jak zelenou, tak i červenou a modrou složku. Poté je pro identifikaci tmavých skvrn nutné převést zelenou složku ve stupních šedi na tzv. binární obraz, jehož pixely mají buď hodnotu 0 či 1. Jednotlivé hodnoty jsou pixelům přiřazeny podle předem stanovené prahové hodnoty, která byla určena pomocí zmiňované lokální prahové adaptivní binarizace [30].

Tento typ binarizace byl použit z důvodu velkých rozdílů v intenzitě a jasu mezi popředím (=oblast zájmu) a pozadím snímku. Obecně je binarizace metoda, jejíž výstupem je binární obraz skládající se pouze z hodnot 1 a 0. Globální binarizace využívá jednoho daného prahu pro celý snímek, tak jako například u klasického prahování (thresholding).

$$g(x) = \begin{cases} 1 & \text{pro } f(x) \geq T; \\ 0 & \text{jinde.} \end{cases} \quad (8)$$

V tomto případě je nevýhodou hledání optimálního prahu T , který se mění pro různé vstupní snímky. U lokální binarizace, která zde byla použita, je hodnota prahu vypočtena postupně pro každý pixel a je implementována pomocí funkce *adaptthresh()*. U této funkce je v tomto případě nutné nastavit dva parametry. První parametr nám říká, které pixely jsou chápány jako popředí. Defaultně je tento parametr nastavený tak, že se jako popředí považují světlejší pixely. Jak však bylo řečeno, zde je oblast zájmu reprezentována tmavšími pixely, a právě proto je tento parametr nastavený jako „dark“, aby bylo zřejmé, že popředí je tmavší než pozadí. Druhý parametr určuje statistiku, která je použita k výpočtu lokálního prahu pro každý pixel zvlášť. Zde byla využita tzv. Bradleyho metoda, která porovnává hodnoty jasu jednotlivých pixelů se střední hodnotou jasu okolí. Rovnice pro výpočet velikosti okolí je uvedena v kapitole 4.2 (rovnice 2). Střední hodnota μ je určena pomocí klouzavého okna, které se pohybuje po obraze, přičemž uprostřed okna se nachází daný pixel, pro který je jasová hodnota vypočtena. Pokud má aktuální pixel o T procent nižší jas, než je střední hodnota jasu okolních pixelů nacházejících se v daném okně, je daný pixel nastaven na černou, v opačném případě na bílou barvu [30; 40].

$$T = \mu \cdot \left(1 - \frac{k}{100}\right) \quad (9)$$

Po převedení zelené složky ve stupních šedi na obraz binární je problémem to, že se nám na výstupu objeví jak retinální léze, tak i cévy, které zde mají stejné vlastnosti, ale které nejsou oblastí zájmu. Z toho důvodu jsou následně využity některé morfologické operace v požadovaném sledu [18; 30; 40].

Nejprve byla využita morfologická operace uzavření, která umožňuje vyplnění malých děr vzniklých v retinálních lézích dosavadní úpravou snímku. Uzavření je definováno jako dilatace (\oplus) s následnou erozí (\ominus) a lze ji popsat následující rovnicí:

$$A \bullet B = (A \oplus B) \ominus B. \quad (10)$$

Následně je využita mediánová filtrace k potlačení šumových oblastí. Název filtrace je odvozen od parametru medián, který představuje hodnotu ležící uprostřed vzestupně seřazených hodnot. Při implementaci této filtrace je nutné zvolit velikost okna, které klouže po obraze a definuje tak hodnoty, které mají být seřazeny. V tomto případě byla velikost okna zvolena jako 10x10 pixelů. Potlačení šumu dojde k odstranění malých shluků pixelů [18; 30].

Na závěr je použita morfologická operace eroze s čtvercovým strukturním elementem pro vyhlazení hranic objektů. Eroze funguje na principu odečítání dvou bodových množin pomocí vektorového rozdílu a je definována jako:

$$X \ominus B = \{p \in \varepsilon^2, p + b \in X, \forall b \in B\}, \quad (11)$$

kde:


p ...je označení pro pixel,

ε^2 ...je binární obrazový prostor,

X ...je bodová množina (=původní obraz vstupující do operace),

B ...je strukturní element.

Obrazové výstupy po adaptivní binarizaci a morfologických operacích, které vedou k vytvoření inicializační masky jsou vyobrazeny níže (viz Obrázek 36 a Obrázek 37) [18; 30; 40].



Obrázek 36: Obrazové výstupy prvního celku segmentačního algoritmu lézí, A – vstupní snímek, B – extrahovaná zelená složka ve stupních šedi, C – výsledek po adaptivní binarizaci, D – výsledek po morfologických operacích



Obrázek 37: Příklady inicializačních (počátečních) masek

6.1.2 Lokální detekce a deskripce prvků (SURF)

Metoda využívající SURF (Speeded-Up Robust Features) detektor slouží ke konstrukci výpočetně rychlého a stabilního deskriptoru schopného fungovat v reálném čase. Zmiňovaný detektor je použit na zelenou složku původního snímku ve stupních šedi. Před jeho implementací je ale potřeba snímek vyhladit pomocí mediánové filtrace, která byla popsána výše [30].

Samotný SURF detektor je principiálně inspirován tzv. SIFT (Scale-Invariant Feature Transform) detektorem, který se používá za účelem detekce objektů v obraze. SURF detektor se však od svého předchůdce liší zejména svou rychlostí, které bylo dosaženo sestavením měřítkově nezávislé

reprezentace obrazu (scale-space) a redukcí velikosti výsledných deskriptorů. SURF detektor detekuje významné obrazové body pomocí determinantu Hessianovy matice, která je definována jako:

$$H(x, y, \sigma) = \begin{bmatrix} L_{xx}(x, y, \sigma) & L_{xy}(x, y, \sigma) \\ L_{yx}(x, y, \sigma) & L_{yy}(x, y, \sigma) \end{bmatrix}, \quad (12)$$

kde $L_{xx}(x, y, \sigma)$ představuje hodnotu druhé parciální derivace podle x konvoluce vstupního obrazu $I(x, y)$ s Gaussovou funkcí $G(x, y, \sigma)$ s měřítkem σ v bodě (x, y) . Determinant Hessianovy matice je poté vypočítán podle vztahu:

$$\text{Det}(H_{\text{approx}}) = D_{xx}D_{yy} - (wD_{xy})^2, \quad (13)$$

kde:

D_{xx} , D_{yy} a D_{xy} ...jsou obrazy vzniklé obdélníkovou filtrací,

w ...je váha použitá pro aproximaci Gaussova jádra (empiricky stanovena na hodnotu 0,9).

Rychlý výpočet determinantu je umožněn aplikací integrálního obrazu, který představuje strukturu vybudovanou nad vstupním obrazem danou vztahem:

$$I_{\Sigma}(x, y) = \sum_{i=0}^{i \leq x} \sum_{j=0}^{j \leq y} I(i, j), \quad (14)$$

kde:

$I(i, j)$...je vstupní obraz,

$I_{\Sigma}(x, y)$...je integrální obraz.


Integrální obraz tedy provádí součet všech hodnot uvnitř obdélníkové oblasti vstupního obrazu vyjádřený rovnicí:

$$\Sigma = A - B - C + D, \quad (15)$$

kde:

Σ ...je hledaný součet,

A, B, C, D ...jsou hodnoty integrálního obrazu v daných souřadnicích (Obrázek 38).




Obrázek 38: Princip výpočtu součtu využitím integrálního obrazu

Jak již bylo řečeno, SURF detektor využívá pro lokalizaci významných bodů měřítkově nezávislou reprezentaci (scale-space), která je důležitá pro stabilní detekci bodů i při změně měřítka obrazu. Scale-space je v případě metody SURF sestavena z jednotlivých obrazů vzniklých filtrací. Použitím integrálního obrazu je zachována výpočetní složitost i při zvětšení filtračního jádra. Významné body jsou ve scale-space detekovány pomocí Hessianovy matice jako maxima a jsou nalezeny porovnáním jednotlivých hodnot sousedních bodů. Pokud má daný bod v okolí nejvyšší hodnotu, je považován za bod významný. Přesná lokalizace takového bodu je zpřesněna Taylorovým rozvojem, jehož výstupem je sub-pixelová a sub-měřítková poloha významného bodu [30; 41].

Značnou nevýhodou SURF detektoru je to, že detekuje jak světlé, tak tmavé pixely. Z toho důvodu, je následně aplikováno další filtrování, které zachovává pouze ty pixely, které byly detekovány prvním logickým celkem celého algoritmu. Konceptně tedy bereme průsečík mezi oblastmi detekovanými adaptivní binarizací spolu s morfologickými operacemi a SURF detektorem [30; 41].

Obrázek 39 obsahuje obrazové výstupy jednotlivých částí druhého celku algoritmu určeného k segmentaci lézí [30; 41].



Obrázek 39: Obrazové výstupy druhého celku segmentačního algoritmu lézí, A – mediánová filtrace zelené složky, B – lokace významných pixelů pomocí SURF detektoru, C – potvrzené léze detekované binarizací a současně SURF detektorem, D – pravděpodobné léze nedetekované SURF detektorem


6.1.3 Semisupervizorní identifikace

Poslední částí tohoto algoritmu, který byl použit za účelem segmentace retinálních lézí ze snímků očního pozadí, je tzv. semisupervizorní identifikace. Tato část zde byla použita z důvodu rozpoznání nejednoznačných oblastí dosavadního průběhu segmentace. Pod pojmem nejednoznačné oblasti jsou označeny ty pixely lézí, které byly detekovány adaptivní binarizací, ale ne SURF detektorem. Tudíž je pravdivost jejich identifikace potřeba ověřit. Rovněž se zde řadí pravděpodobné léze detekované pouze adaptivní binarizací [30].


Semisupervizorní identifikace kombinuje supervizorní a neřízené strojové učení, při němž je většina dat neoznačena a jen malá podmnožina dat je označena. Semisupervizorní strategie použitého algoritmu nejprve seskupí oblasti lézí identifikovaných pomocí adaptivní binarizace do dvou skupin na základě morfologických vlastností, kterých bylo využito celkem šest – excentricita,

ekvivalentní průměr, pevnost, obvod plochy, kruhovitost a poslední poměr vedlejší a hlavní osy. Seskupení (indexování) je uskutečněno pomocí k-means algoritmu, pomocí kterého získáme snímek obsahující dva shluky regionů. Shlukové indexy však neobsahují žádnou informaci o tom, který z nich odpovídá oblastem lézí a který nikoliv. Právě proto je zde využito konceptu semisupervizorního učení, který tento problém kompenzuje. Prvním krokem konceptu je nalezení tzv. nejvýznamnějšího pixelu, který odpovídá nejsilnějšímu SURF pixelu, který se nachází vždy v oblasti retinální léze. Jakmile je tento pixel identifikován, lze jeho umístění a index shluku získat z výsledku shlukovací analýzy. Pro vytvoření výsledného obrazu (Obrázek 40) jsou zachovány pouze ty oblasti, které mají stejný index shluku jako tento nejvýznamnější pixel. Sumarizace výsledků segmentace je znázorněna níže (viz Obrázek 41).

Tabulka 10 obsahuje ukázkou nastavených parametrů pro algoritmus určený k segmentaci retinálních lézí [30].



Obrázek 40: Příklady výsledků získaných výše popsáním algoritmem



Obrázek 41: Sumarizace výše popsání algoritmu, originální snímek (vlevo), segmentační masku (uprostřed), segmentované oblasti z originálního snímku (vpravo)


Tabulka 10: Hodnoty nastavené v algoritmu pro segmentaci lézí [30]

Adaptivní binarizace následovaná morfologickými operacemi		
Mediánová filtrace	velikost filtrační masky	[10 10]
Eroze	strukturní element	Square, 3
Lokální detekce a deskripce prvků (SURF)		
Mediánová filtrace	velikost filtrační masky	[12 12]

6.2 Algoritmus pro segmentaci cévního řečiště

Algoritmus pro segmentaci cévního řečiště představuje druhý algoritmus, který byl použit v rámci navrhovaného hybridního algoritmu. Tento algoritmus byl použit za účelem odstranění chybně segmentovaných částí cévního řečiště výše popsaným algoritmem, jak je patrné z ukázky výše (Obrázek 40). Ze samotné definice retinálních lézí, které jsou definované jako tmavé a ve většině případů jako kruhovitě či elipsovité útvary objevující se na očním pozadí, je patrné, že výsledek získaný pouze pomocí algoritmu pro segmentaci retinálních lézí není zcela přesný. Právě z toho důvodu bylo potřeba jej doplnit a chyby eliminovat.

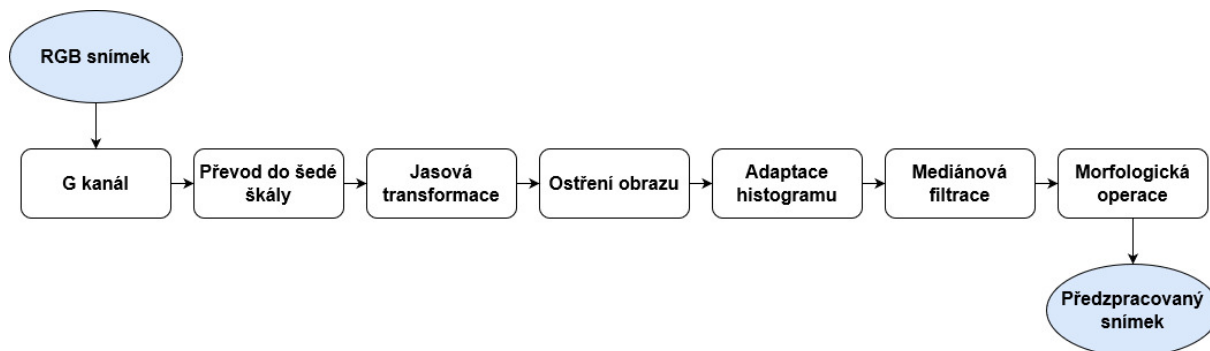
Samotný algoritmus určený pro segmentaci cévního řečiště, jehož schéma je znázorněno níže (Obrázek 42), se skládá ze dvou hlavních částí, a to z předzpracování a následné segmentace obrazu. V obou částech bylo provedeno několik základních úprav a kroků, které vedly jak ke zvýraznění cévního řečiště, tak k co možná nejrobustnější segmentaci. Na druhou stranu je důležité si uvědomit, že každý snímek je jiný, ať už v pořizovací kvalitě, která souvisí s množstvím přítomného šumu, tak v rozložení jednotlivých částí očního pozadí. To znamená, že při nastavení jednotlivých parametrů či prahů pro jednotlivé kroky je v podstatě využít kompromis [19].



Obrázek 42: Blokové schéma algoritmu určeného pro segmentaci cévního řečiště


6.2.1 Předzpracování obrazu

Předzpracování obrazu je prvním a velice důležitým bodem každého zpracování obrazu, neboť se zde zaměřujeme především na metody, které jsou schopny potlačit přebytečný šum, odstranit zkreslení či zvýraznit popředí od pozadí. Při správně zvolené posloupnosti jednotlivých úprav je možné detekovat a extrahovat důležité informace i ze snímků s horší pořizovací kvalitou. Před každým předzpracováním je tedy nezbytně nutné vědět, které části obrazu představují oblast zájmu, a které nikoliv. U výše popsaného algoritmu zaměřeného na segmentaci lézí to byly jednoznačně retinální léze, kdežto tady představují oblast zájmu retinální cévy a retinální léze jsou tím pádem součástí pozadí. Celý proces předzpracování zvolený v rámci popisovaného algoritmu je znázorněn na níže uvedeném blokovém schématu (viz Obrázek 43) [19].



Obrázek 43: Blokové schéma předzpracování obrazu

V prvním kroku je z barevného (RGB) snímku extrahována zelená chrominanční složka (tzv. G kanál), která oproti dvěma zbývajícím (R – red, B – blue) disponuje největším kontrastem mezi cévami a pozadím. Extrakcí zelené složky získáme z 3D obrazu obraz dvojrozměrný (2D), který je poté převeden do šedé škály. V následujícím kroku je využita jasová transformace pro úpravu jasových hodnot vstupního obrazu, která má za následek změnu vstupních intenzitních hodnot. V praxi získáme zesvětlený obraz se zvýrazněným kontrastem mezi popředím a pozadím. Poté bylo aplikováno ostření obrazu za účelem zdůraznění vyšších frekvencí obrazu představujících ostré hrany objektů. Ostřením obrazu získáme strmější hrany, a tudíž i ostřejší a výraznější cévní řečiště. Následně je využita adaptace histogramu, která využívá všechny hodnoty intenzit se stejnou četností, což se projeví zvýšeným kontrastem. Na dosavadně upravený snímek je v neposlední řadě aplikována mediánová filtrace, která se projevuje vyhlazením obrazu, jelikož potlačuje přebytečný šum obsažený v obraze. Poslední částí využitou v rámci předzpracování obrazu je morfologická operace dilatace s lineárním strukturním elementem pro vyhlazení obrazu. Obrázek 44 znázorňuje obrazové výstupy po jednotlivých blocích předzpracování [19].




Obrázek 44: Obrazové výstupy procesu předzpracování

6.2.2 Segmentace obrazu

Jakmile je obraz předzpracován, přichází na řadu samotná segmentace. Hlavním principem segmentace je oddělení (extrakce) pixelů popředí od pixelů pozadí. Oblast zájmu je na konci segmentačního procesu reprezentována barvou bílou, kdežto černou barvou je reprezentováno vše,

co se nachází mimo tuto zájmovou oblast. V současné době existuje nepřehledné množství segmentačních metod. V algoritmu určeném k segmentaci cév byla použita metoda založená na principu maximum principal curvature. Obrázek 45 znázorňuje posloupnost jednotlivých částí této metody [19].



Obrázek 45: Blokové schéma segmentace obrazu

V první části zvolené segmentační metody dochází ke generování masky výstupního snímku pomocí dvou oddílů – binarizace a následné eroze. Poté je implementován Gaussův filtr využívající Gaussovské vyhlazovací jádro se směrodatnou odchylkou o hodnotě 1,45. Filtr předzpracovaný snímek vyhladí a vypočítá druhou derivaci obrazové funkce vyhlazeného snímku. Na odfiltrovaný snímek je následně aplikována samotná metoda maximum principal curvature pracující ve dvou fázích. V rámci první fáze je vypočtena dvourozměrná vektorová veličina mající velikost a směr měnící se v každém bodě:

$$|\nabla f(x, y)| = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2} \quad (16)$$

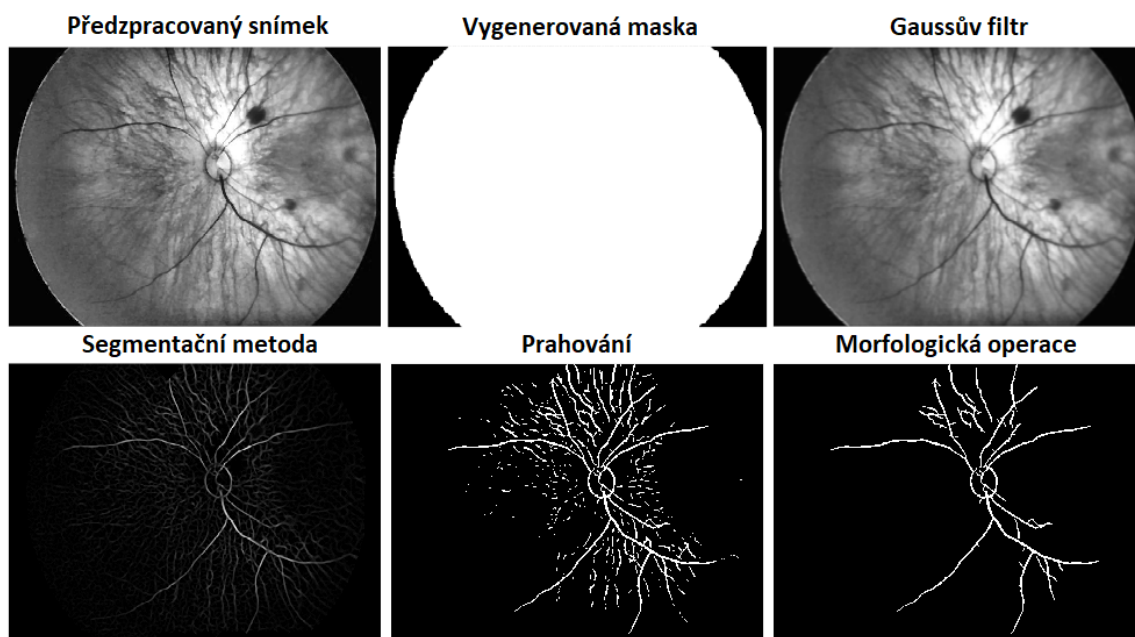
$$\Psi(x, y) = \text{arg} \left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y} \right). \quad (17)$$

Tato veličina je známá jako gradient. Druhá fáze slouží k nalezení tzv. hlavního zakřivení obrazu s využitím Hessianovy matice:

$$H = \begin{pmatrix} G_{xx} & G_{xy} \\ G_{yx} & G_{yy} \end{pmatrix}. \quad (18)$$

Hlavní zakřivení popisuje změnu gradientu intenzity vzhledem k sousedním pixelům. Výstupem zvolené segmentační metody je stále šedo tónový snímek s již dobře rozpoznatelnými cévami. V předposledním kroku segmentace je pomocí globálního prahu snímek ve stupních šedi převeden na černobílý binární snímek na základě rozdílných úrovní jasových intenzit. Na závěr je využita morfologická operace otevření, definována vztahem níže, k odfiltrování malých částí, které obsahují menší počet pixelů než předem definovaná hodnota. Výstupy po jednotlivých krocích segmentace obrazu jsou znázorněny níže (Obrázek 46) [19].

Tabulka 11 opět obsahuje všechny hodnoty parametrů nastavených v rámci algoritmu určeného k segmentaci cév [19].



Obrázek 46: Obrazové výstupy segmentace obrazu

Tabulka 11: Hodnoty nastavené v algoritmu pro segmentaci cév [19]

Předzpracování obrazu

Ostření	síla efektu zaostření	0.2
Mediánová filtrace	velikost filtrační masky	[4 4]
Dilatace	strukturní element	line (1, 30)


Segmentace obrazu

Eroze	strukturní element	diamond (20)
Střední kvadratická odchylka	rozptyl Gaussova jádra	1.45
Otevření	strukturní element	200

6.3 Implementace hybridního algoritmu

Jak již bylo uvedeno výše, hybridní algoritmus kombinuje minimálně dva algoritmy, které řeší stejný problém v rámci jednoho vstupního obrazu. Jelikož zde byly použity dva rozdílné algoritmy pro segmentaci, nebylo těžké je spojit a využít je k tvorbě dostatečně robustního algoritmu pro co nejefektivnější detekci a identifikaci pouze a jen retinálních lézí.

Níže popsaný hybridní algoritmus, jehož schéma je znázorněno níže (Obrázek 47), kombinuje výsledky dvou výše popsaných segmentačních algoritmů za účelem zkvalitnění algoritmu pro segmentaci retinálních lézí. Nejprve dochází k načtení obou segmentovaných snímků, které jsou od sebe následně odečteny a získaný výsledek je upraven pomocí dvou po sobě jdoucích morfologických operací.




Obrázek 47: Blokové schéma hybridního algoritmu

V prvním kroku jsou načteny všechny výsledky obou segmentací. Výsledky segmentací byly postupně ukládány do dvou samostatných matic podle toho, o jakou segmentaci se jednalo. To

znamená, že byly získány dvě samostatné matice o stejné velikosti, přičemž jedna matice obsahuje výsledky po segmentaci lézí, kdežto druhá matice obsahuje pouze výsledky po segmentaci cév.

Jakmile jsou snímky načteny, přichází na řadu jejich odečtení, odborně subtrakce. U tohoto kroku je velmi důležité si uvědomit, který výsledek segmentace je pro celkové řešení majoritní, zda léze či cévy. Už jen ze samotného názvu diplomové práce je patrné, že majoritní jsou zde retinální léze, a tudíž je od tohoto výsledku odečten výsledek získaný segmentací cév. Celý princip subtrakce je založen pouze na odečtení pixelů jednoho snímku od druhého (viz Obrázek 48).



Obrázek 48: Princip subtrakce, a) snímek získaný algoritmem pro segmentaci lézí, b) snímek získaný algoritmem pro segmentaci cév, c) snímek získaný odečtením snímku b od snímku a

Z ukázky výše je zřejmé, že výsledek po subtrakci není ideální. Právě proto je potřeba jej dopravit. K úpravě byly využity dvě po sobě jdoucí morfologické operace – otevření a uzavření. V rámci morfologických operací se využívají různé matematické operace spolu s vlastnostmi bodových množin pro extrakci požadovaných struktur, zjednodušení tvarů objektů či k odstranění přebytečného šumu. U každé morfologické operace je potřeba definovat tzv. strukturní element, který představuje menší bodovou množinu pohybující se po obraze. Morfologická operace otevření zde byla použita k odfiltrování malých shluků pixelů, kdežto morfologická operace uzavření byla použita za účelem vyplnění hluchých míst neboli děr vzniklých v oblastech retinálních lézí. Výsledky a tabulka nastavených hodnot pro aplikaci těchto operací jsou uvedeny níže (Obrázek 49 a Tabulka 12) [18; 19].


Tabulka 12: Tabulka zvolených parametrů pro morfologické operace hybridního algoritmu

Hybridní algoritmus


Otevření	velikost strukturního elementu	100
Uzavření	strukturní element	disk, 5

Pro lepší vizuální hodnocení dosavadního řešení navrhovaného algoritmu byla použita fúze zelené chrominanční složky nativního snímku spolu s dosavadními segmentovanými lézemi. Díky

procesu fúzování pozorujeme po implementaci hybridního algoritmu stále dva zásadní nežádoucí jevy, a to segmentaci oblastí v blízkosti optického disku a segmentaci částí cévního řečiště (viz Obrázek 50), které se nepodařilo odečíst, jelikož i algoritmus pro segmentaci cév má své limity. Oba tyto jevy však mají společnou jednu podstatnou vlastnost. Míra kruhovitosti těchto objektů je výrazně nižší než míra kruhovitosti lézí, a právě tento fakt je využit v následujícím bloku celého algoritmu [18; 19].



Obrázek 49: Implementace morfologických operací, a) otevření s hodnotou strukturního elementu 100, b) uzavření se strukturním elementem tvaru *disk* a hodnotou parametru 5



Obrázek 50: Fúze dosavadních výsledků, a) znázornění odečtených (zelená barva) a přičtených (fialová barva) pixelů v rámci použití morfologických operací, b) znázornění segmentace nežádoucích částí

6.4 Postprocessing založený na kruhovitosti

Navrhovaný postup postprocessingu vychází z faktu, že oblasti retinálních lézí mají charakteristický kruhovitý či oválný tvar. Tím pádem se vyznačují dostatečně velkou mírou kruhovitosti, přičemž kruhovitost je definována jako hodnota používající se k vyčíslení chyb kružnice. Algoritmus použitý ke stanovení této hodnoty pro jednotlivé léze se skládá ze tří hlavních bloků (Obrázek 51) [41].




Obrázek 51: Blokové schéma postprocessingu

Nejprve je potřeba načíst výsledky hybridního algoritmu, které byly uloženy ve formě matice. Po načtení vstupních snímků je potřeba najít vnější hranice jednotlivých segmentovaných objektů v obraze, neboť právě na základě těchto hranic jsou následně získány jejich metriky potřebné ke stanovení míry kruhovitosti. Hranice objektu (lézí) jsou ohraničeny bílou barvou [41].


Posledním krokem je výpočet kruhovitosti, pro kterou je důležité zjistit plochy a obvody ohraničených objektů, které chceme hodnotit. Jakmile tyto hodnoty zjistíme, můžeme míru kruhovitosti vypočítat ze vztahu:

$$kruhovitost = \frac{4\pi \cdot plocha}{obvod^2}. \quad (19)$$

Míra kruhovitosti nabývá hodnot od 0 do 1 s tím, že číslu 1 je rovna pouze tehdy, jedná-li se o kruh. Jakmile máme výsledek pro všechny léze obrazu, je potřeba stanovit prahovou hodnotu, která definuje, které léze budou ve výsledku ponechány a které budou odstraněny. V tomto algoritmu byla prahová hodnota nastavena na hodnotu 0,60. Prahová hodnota byla zvolena na základě obrazových výstupů algoritmu s vyznačenými hodnotami kruhovitosti (viz Obrázek 52 uprostřed). V praxi to znamená to, že všechny léze s menší hodnotou kruhovitosti, než je 0,60 budou z výsledného snímku odstraněny. Najít optimální hodnotu prahu bylo značně obtížné, jelikož nikde není definované, jaké nejmenší míry kruhovitosti mohou retinální léze nabývat. Obrázek 52 opět znázorňuje jednotlivé výstupy získané postprocessingem, které byly rovněž doplněny fúzí obrazu pro lepší vizuální hodnocení (Obrázek 53) [41].



Obrázek 52: Výstupy získané navrhovaným postprocessingem, snímky získané subtrahací (vlevo), snímek s nalezenými vnějšími okraji segmentovaných lézí a vyznačenou mírou kruhovitosti (uprostřed), konečný výsledek po implementaci algoritmu využívajícího kruhovitost (vpravo)




Obrázek 53: Fúze výstupů kruhovitosti

7 Objektivní posouzení kvality algoritmu

Následující kapitola je věnována objektivnímu posouzení kvality a robustnosti navrhovaného algoritmu. V rámci objektivní analýzy jsou všechny získané výsledky porovnány s tzv. zlatými


standardy. Zlatým standardem je v tomto konkrétním případě označován manuálně segmentovaný snímek v binárním tvaru. To znamená, že retinální léze jsou bílé, kdežto okolí (pozadí) je reprezentováno barvou černou.

Samotná objektivní analýza s využitím objektivizačních parametrů a indikátorů kvality je provedena ve dvou krocích. V rámci prvního kroku byly výsledky navrhovaného algoritmu porovnány se zlatými standardy, které byly vytvořeny na základě těchto výsledků. To znamená, že tyto zlaté standardy obsahovaly pouze ty retinální léze, které dokázal vytvořený algoritmus detekovat. Na základě tohoto kroku objektivní analýzy byly získány výsledky, které odráží míru a rozsah detekce. Tento krok byl do procesu objektivní analýzy zařazen z toho důvodu, že velká část získaných výstupů sice dokázala detekovat správné umístění dané léze, ale už ji nedokázala detekovat v plném rozsahu (viz Obrázek 54).



Obrázek 54: Porovnání výsledku získaného pomocí navrhovaného algoritmu (vlevo) a zlatého standardu vytvořeného na základě tohoto výsledku (vpravo)

Ve druhém kroku byly výsledky algoritmu porovnány se zlatými standardy, které již obsahují všechny léze detekovatelné okem pozorovatele. Tímto porovnáním byla zjištěna celková robustnost a efektivita navrhovaného algoritmu pro segmentaci retinálních lézí. Z přiložených obrázků (Obrázek 55 a Obrázek 56) je zřejmé, že v některých případech je algoritmus téměř stoprocentní, kdežto v některých případech je schopnost detekce sledovaného jevu naprosto mizivá. Neschopnost detekce retinálních lézí může být podmíněna jak nedostatečnou kvalitou testovaných snímků, tak i možným nesprávným přístupem v některé části algoritmu.



Obrázek 55: Příklad úspěšné detekce všech retinálních lézí přítomných v obraze



Obrázek 56: Příklad neúspěšné detekce retinálních lézí

7.1 Objektivizační parametry použité k objektivnímu posouzení kvality algoritmu

Jak již bylo zmíněno výše, kvalita navrhovaného algoritmu byla testována pomocí dvou skupin analyzátorů. První skupinu tvoří tzv. objektivizační parametry, které fungují na principu porovnávání dvou snímků. Mezi nejznámější a nejvíce využívané parametry patří strukturní index podobnosti, střední kvadratická chyba a korelační koeficient. Všechny zmíněné parametry porovnávají výstupy algoritmu se zlatými standardy, které představují referenci, a jsou detailněji popsány níže.

7.1.1 Strukturní index podobnosti (SSIM)

SSIM se obecně používá pro měření a vyjádření podobnosti dvou snímků, na základě kombinace výpočtů pro jas, kontrast a strukturu:

$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1}, \quad (20)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2}, \quad (21)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3}, \quad (22)$$

kde $\mu_x, \mu_y, \sigma_x, \sigma_y, \sigma_{xy}, C_1, C_2$ a C_3 představují lokální průměry, standardní odchylky, křížovou kovarianci a konstanty definované jako $C_i = (K_i L)^2$. Kombinací těchto tří rovnic získáme vztah pro výpočet SSIM:

$$SSIM(x, y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma, \quad (23)$$

kde α, β a γ jsou výchozí hodnoty exponentů. Zároveň platí, že pokud $\alpha = \beta = \gamma = 1$ a $C_3 = \frac{C_2}{2}$ je možné výpočet indexu zjednodušit následovně:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_x\sigma_y + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}. \quad (24)$$

Tento index nabývá hodnoty od 0 do 1, přičemž 1 vyjadřuje naprostou totožnost snímků [18; 19].

7.1.2 Střední kvadratická chyba (MSE)

MSE je objektivizační parametr vyjadřující přesnost měření (v tomto případě přesnost segmentace). Tento parametr je vypočítán pomocí následující rovnice mezi dvěma snímky se stejnou velikostí:

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^M (X_{i,j} - Y_{i,j})^2, \quad (25)$$

kde $X_{i,j}$ a $Y_{i,j}$ reprezentují hodnoty pixelů dvou porovnávaných snímků. MSE nemá defaultně definovaný rozsah hodnot, kterých může nabývat. Platí zde pouze to, že čím menší hodnoty nabývá, tím je podobnost snímků větší [19].

7.1.3 Korelační koeficient obrazu

Posledním použitým objektivizačním parametrem je korelační koeficient vyjadřující velikost vzájemné korelace dvou snímků x a y . Pojem korelace obecně vyjadřuje míru závislosti dvou veličin. Samotný korelační koeficient je dán vztahem:

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{(\sum_m \sum_n (A_{mn} - \bar{A})^2)(\sum_m \sum_n (B_{mn} - \bar{B})^2)}}, \quad (26)$$

kde \bar{A} je průměr snímku x a \bar{B} je průměr snímku y . Tento koeficient nabývá hodnot od -1 do 1, přičemž vyšší hodnota vyjadřuje větší korelaci a tím i větší podobnost snímků [19].

7.2 Indikátory kvality použité k objektivnímu posouzení kvality algoritmu

Indikátory kvality tvoří druhou skupinu analyzátorů použitých pro hodnocení kvality a efektivity navrhovaného algoritmu. Opět se zde porovnává výsledek algoritmu se zlatým standardem. V této práci byly použity tři indikátory, které vznikly odvozením z tzv. kvantitativních ukazatelů kvality, a to senzitivita, specificita a přesnost. Tyto tři indikátory jsou definovány pomocí čtyř různých detekčních případů, které mohou v průběhu analýzy nastat. Konkrétně se jedná o:

- TP (*true positive*) – případ vyjadřující správně detekované pixely popředí,
- TN (*true negative*) – případ vyjadřující správně detekované pixely pozadí, opak k TP,
- FP (*false positive*) – nesprávné přiřazení pixelů pozadí k pixelům popředí,
- FN (*false negative*) – nesprávné označení pixelů popředí jako pixely pozadí, opak k FP [19].

7.2.1 Senzitivita

Senzitivita nebo také citlivost je indikátor kvality vyjadřující úspěšnost zachycení sledovaného jevu navrhovaným algoritmem. V tomto konkrétním případě se jedná o schopnost algoritmu extrahovat a detekovat retinální léze přítomné v obraze. Tento indikátor nabývá hodnot v rozmezí od 0 do 1 a opět platí, že čím vyšší hodnota výsledku, tím lépe. Senzitivita bývá v mnoha případech označována zkratkou TPR (*true positive rate*) a vztah pro její výpočet je následující [19]:

$$\text{Senzitivita} = \frac{\text{počet skutečně pozitivních}}{\text{počet skutečně pozitivních} + \text{počet falešně negativních}} = \frac{TP}{TP + FN}. \quad (27)$$

7.2.2 Specifická

Specifická je známá pod zkratkou TNR (true negative rate) a vyjadřuje schopnost algoritmu vybrat ty případy, u nichž sledovaný jev nenastal. V rámci této diplomové práce se tedy jedná o schopnost správné detekce pixelů pozadí. Tento indikátor je vypočítáván ze vztahu:

$$\text{Specifická} = \frac{\text{počet skutečně negativních}}{\text{počet skutečně negativních} + \text{počet falešně negativních}} = \frac{TN}{TN + FP} \quad (28)$$

Výsledná hodnota specifickosti se rovněž pohybuje v rozmezí od 0 do 1 a opět chceme dosáhnout co nejvyšší hodnoty [19].

7.2.3 Přesnost

Přesnost je poslední použitý indikátor kvality vyjadřující celkovou přesnost algoritmu, která je vypočítána ze vztahu:

$$\text{Přesnost} = \frac{TP + TN}{TP + FP + FN + TN} \quad (29)$$

Stejně jako u předchozích dvou indikátorů i zde chceme dosáhnout co možná nejvyšší hodnoty rozsahu, který je opět od 0 do 1 [19].

7.3 Zhodnocení výsledků získaných objektivním posouzením kvality

Výsledky obou kroků objektivní analýzy získané výše popsány parametry a indikátory jsou v následující kapitole sepsány do přehledných tabulek a slovně interpretovány. Jak již bylo zmíněno v kapitole 5.1, výsledná verze navrhovaného algoritmu byla testována celkem na 38 snímcích sítnice předčasně narozených dětí. Na všech snímcích se objevují retinálních lézí. Rovněž je důležité připomenout, že v této kapitole pracujeme s výsledky algoritmu, u kterého byla prahová hodnota kruhovitosti nastavena na hodnotu 0,60.

Nejprve zde budou popsány a zobrazeny výsledky objektivního hodnocení pro výsledné snímky, které byly porovnány se zlatými standardy vzniklými na základě dosažených výsledků algoritmu (viz Tabulka 13). Začneme-li slovní interpretací výsledků získaných pomocí objektivizačních parametrů je zřejmé, že si jsou všechny testované snímky opravdu podobné. Nejmenší podobnost mezi výsledným snímkem a zlatým standardem je pozorovatelná u snímku Test 8, jelikož hodnota SSIM je rovna číslu 0,926. Celková průměrná hodnota parametru SSIM je však 0,962, což svědčí o velice vysoké podobnosti. Na základě průměrné hodnoty MSE, která vyšla 799,6, se dá říct, že přesnost segmentace je dostatečně vysoká. Výsledek korelačního koeficientu, jehož průměrná hodnota je rovna číslu 0,717, vypovídá o dostatečné, ne však ideální, korelaci porovnávaných snímků.

Druhá polovina tabulky obsahující výsledky indikátorů kvality lze slovně interpretovat následovně. Navrhovaný algoritmus dokáže správně detekovat, a tedy i segmentovat, pouze 51,4 % všech pixelů, které by měl teoreticky zachytit. Na druhou stranu je nutné vyzdvihnout fakt, že se algoritmus ve svých výsledcích prakticky nemýlí, neboť průměrná hodnota přesnosti je 98,1 %. To znamená, že si u každého segmentovaného pixelu můžeme být na 98 % jistí, že je detekovaný správně, tudíž v oblasti retinální léze. Průměrná hodnota specifickosti (99,1 %) hovoří o téměř bezchybné detekci pixelů pozadí tam, kde se skutečně nacházejí.

Tabulka 13: Výsledky objektivního posouzení kvality pro zlaté standardy vytvořené na základě výsledků algoritmu s prahem 0,60

Snímek	SSIM	MSE	Korelační koeficient	Senzitivita	Specifická	Přesnost
Test 1	0,990	151,4	0,800	0,623	0,996	0,994
Test 2	0,947	1579,9	0,525	0,210	0,996	0,975
Test 3	0,969	416,3	0,854	0,702	0,988	0,983
Test 4	0,956	756,9	0,764	0,553	0,988	0,978
Test 5	0,951	1011,1	0,758	0,565	0,991	0,978
Test 6	0,951	1011,2	0,762	0,576	0,991	0,978
Test 7	0,937	1538,3	0,683	0,407	0,993	0,971
Test 8	0,926	1750,8	0,687	0,409	0,991	0,966
Test 9	0,932	1707,0	0,587	0,449	0,977	0,963
Test 10	0,958	732,9	0,756	0,609	0,984	0,977
Test 11	0,963	687,1	0,717	0,457	0,994	0,984
Test 12	0,959	775,6	0,766	0,617	0,982	0,975
Test 13	0,943	1054,3	0,778	0,510	0,987	0,971
Test 14	0,942	1335,2	0,691	0,509	0,988	0,972
Test 15	0,932	1271,9	0,806	0,621	0,984	0,967
Test 16	0,948	955,5	0,784	0,555	0,988	0,975
Test 17	0,933	1750,9	0,641	0,366	0,992	0,968
Test 18	0,993	200,4	0,314	0,299	0,997	0,996
Test 19	0,954	879,0	0,729	0,551	0,986	0,976
Test 20	0,981	336,5	0,754	0,594	0,993	0,989
Test 21	0,984	244,4	0,830	0,577	0,996	0,992
Test 22	0,987	183,7	0,873	0,649	0,996	0,992
Test 23	0,966	642,0	0,734	0,620	0,987	0,981
Test 24	0,967	749,9	0,659	0,400	0,991	0,982
Test 25	0,943	1720,8	0,604	0,289	0,994	0,969
Test 26	0,948	1134,3	0,739	0,520	0,993	0,978
Test 27	0,982	408,9	0,676	0,587	0,994	0,991
Test 28	0,959	963,8	0,590	0,310	0,991	0,980
Test 29	0,968	762,4	0,675	0,356	0,997	0,986
Test 30	0,979	396,1	0,748	0,637	0,991	0,988
Test 31	0,963	620,9	0,813	0,603	0,990	0,982
Test 32	0,968	448,5	0,856	0,673	0,990	0,984
Test 33	0,954	869,4	0,794	0,578	0,988	0,975
Test 34	0,968	464,5	0,845	0,671	0,990	0,984
Test 35	0,992	150,6	0,592	0,537	0,995	0,995
Test 36	0,991	168,6	0,766	0,468	0,998	0,996
Test 37	0,979	445,2	0,718	0,442	0,998	0,992

Test 38	0,995	110,0	0,594	0,437	0,998	0,997
Průměrná hodnota	0,962	799,6	0,717	0,514	0,991	0,981

Co se týče výsledků získaných porovnáním výsledných snímků algoritmu se zlatými standardy se všemi lézemi detekovatelným pouhým okem je nutné konstatovat to, že jsou ve všech sledovaných parametrech horší (viz Tabulka 14). Vzhledem k tomu, že se nám změnil pouze zlatý standard (rozrostl se o další pixely lézí) a výsledek nikoli, se však není čemu divit. V rámci objektivizačních parametrů došlo k nejmenšímu zhoršení u SSIM, konkrétně z hodnoty 0,962 na hodnotu 0,925, na základě které, je však stále možné tvrdit, že si jsou porovnávané snímky podobné. Průměrná hodnota MSE vzrostla o 1462,6 na 2262,2 a podle této hodnoty je jasné, že výsledná segmentace není dostatečná. Vzájemná korelace se při použití těchto zlatých standardů snížila na průměrnou hodnotu 0,541.

Podle výsledných průměrných hodnot specifity a přesnosti algoritmus obstál. Přesnost se snížila z 98,1 % na 96,3 %, takže jen o pouhé 1,8 %. Hodnota specifity se dokonce nezměnila vůbec. Důvodem může být fakt, že každý obraz obsahuje ve výsledku přes 300 000 pixelů a většina těchto pixelů tvoří právě pozadí, které je pro výpočet specifity primární. Průměrná hodnota senzitivity se snížila o 20,5 % na 30,9 %. To znamená, že navrhovaný algoritmus dokáže ve výsledku vysegmentovat pouze necelých 31 % všech okem detekovatelných lézí, což není vůbec ideální.

Tabulka 14: Výsledky objektivního posouzení kvality s využitím zlatých standardů obsahujících všechny léze detekovatelné pouhým okem

Snímek	SSIM	MSE	Korelační koeficient	Senzitivita	Specifita	Přesnost
Test 1	0,990	151,4	0,800	0,623	0,996	0,994
Test 2	0,876	4296,1	0,343	0,094	0,996	0,941
Test 3	0,935	1794,1	0,611	0,357	0,988	0,965
Test 4	0,888	3507,8	0,468	0,208	0,987	0,943
Test 5	0,934	1681,4	0,666	0,443	0,991	0,969
Test 6	0,932	1766,9	0,662	0,440	0,991	0,968
Test 7	0,854	5027,8	0,449	0,185	0,992	0,928
Test 8	0,815	6470,2	0,426	0,171	0,990	0,906
Test 9	0,903	2959,3	0,461	0,280	0,976	0,946
Test 10	0,918	2320,9	0,525	0,298	0,984	0,958
Test 11	0,933	1806,5	0,532	0,259	0,994	0,971
Test 12	0,923	1998,7	0,576	0,365	0,982	0,961
Test 13	0,871	3719,2	0,541	0,262	0,987	0,940
Test 14	0,879	3601,7	0,520	0,282	0,989	0,945
Test 15	0,893	2792,6	0,671	0,445	0,983	0,948
Test 16	0,873	3931,3	0,517	0,251	0,988	0,938
Test 17	0,854	4916,3	0,435	0,180	0,991	0,929
Test 18	0,962	1474,8	0,087	0,023	0,997	0,980

Test 19	0,911	2555,5	0,514	0,282	0,985	0,955
Test 20	0,968	802,7	0,582	0,360	0,993	0,984
Test 21	0,972	648,9	0,673	0,376	0,996	0,987
Test 22	0,980	375,2	0,781	0,533	0,996	0,990
Test 23	0,938	1680,4	0,534	0,337	0,987	0,969
Test 24	0,907	3208,0	0,413	0,146	0,992	0,950
Test 25	0,926	2292,6	0,547	0,245	0,994	0,963
Test 26	0,943	1295,2	0,716	0,494	0,993	0,976
Test 27	0,943	2059,0	0,353	0,163	0,994	0,969
Test 28	0,901	3379,6	0,351	0,111	0,99	0,948
Test 29	0,899	3578,3	0,381	0,118	0,997	0,950
Test 30	0,959	1156,3	0,525	0,312	0,991	0,978
Test 31	0,919	2350,9	0,576	0,309	0,990	0,960
Test 32	0,934	1837,2	0,628	0,365	0,990	0,966
Test 33	0,958	1035,7	0,767	0,548	0,988	0,974
Test 34	0,935	1893,6	0,610	0,349	0,990	0,966
Test 35	0,992	150,6	0,592	0,537	0,995	0,995
Test 36	0,991	168,6	0,766	0,468	0,998	0,996
Test 37	0,979	445,2	0,718	0,442	0,998	0,992
Test 38	0,980	834,7	0,233	0,063	0,998	0,987
Průměrná hodnota	0,925	2262,2	0,541	0,309	0,991	0,963


Pro větší přehlednost byla vytvořena tabulka rozdílových hodnot těchto dvou hodnocení (viz Tabulka 15). Jak již bylo řečeno výše, porovnáváme-li výsledek navrhovaného algoritmu se zlatými standardy, které obsahují všechny okem detekovatelné léze, je naprosto logické, že takovéto porovnání bude dosahovat horších výsledků. U všech objektivizačních parametrů (kromě MSE) a indikátorů kvality došlo k poklesu jejich výsledné průměrné hodnoty. U parametru MSE nehovoříme o snížení, nýbrž o zvýšení, neboť právě zvýšení tohoto parametru představuje zhoršení výsledku.

Tabulka 15: Rozdílové hodnoty vyjadřující pokles (respektive zvýšení v případě MSE) pro všechny parametry použité k objektivní analýze výsledků navrhovaného algoritmu s prahovou hodnotou kruhovitosti 0,60


Objektivizační parametry	Pokles/zvýšení hodnoty parametru
SSIM	0,037
MSE	1462,6
Korelační koeficient	0,176
Indikátory kvality	Pokles hodnoty indikátoru
Senzitivita	0,205
Specifická	0,000
Přesnost	0,018

7.4 Testování algoritmu s využitím různých prahových hodnot pro kruhovitost

Následující kapitola se věnuje komparativní analýze výsledků navrhovaného algoritmu s využitím dvou dalších prahových hodnot kruhovitosti (konkrétně 0,50 a 0,70) vůči zlatým standardům obsahující všechny léze. Tato kapitola zde byla zařazena z důvodu zjištění správnosti zvoleného prahu pro volbu vhodného prahu pro implementaci kruhovitosti. Volba vhodného prahu totiž ovlivňuje výsledný snímek algoritmu. Pro ukázkou zde byly vybrány dva snímky, které reprezentují změnu výsledku algoritmu při nastavení tří různých prahových hodnot pro kruhovitost (Obrázek 57). Vrchní ukázka nevykazuje žádné výrazné změny ve výsledku segmentace, až na jednu podstatně velkou lézi v levém rohu. U ukázkou dole je rozdíl ve výsledcích poměrně zřetelný. Snížení prahové hodnoty se na výsledcích nejčastěji projeví zachováním chybně segmentované oblasti optického disku či zachováním těch oblastí, které nepředstavují oblasti retinálních lézí (Obrázek 58).



Obrázek 57: Výsledky algoritmu s různým nastavením prahu pro kruhovitost v porovnání se zlatým standardem (GS)



Obrázek 58: Příklady chybné segmentace při zvolení příliš nízkého prahu (0,50)

Tabulka 16 obsahuje výsledky při nastavení prahu na hodnotu 0,50, kdežto Tabulka 17 zobrazuje výsledky pro práh 0,70. Pro lepší možnost srovnání byla vytvořena Tabulka 18, která obsahuje všechny průměrné hodnoty všech použitých parametrů objektivní analýzy pro všechny tři testované prahy. Z výsledků této komparativní analýzy je možné tvrdit, že z hlediska použitých objektivizačních

parametrů byla volba prahu na hodnotu 0,60 zcela správná, neboť jejich průměrné hodnoty dosahují u tohoto prahu nejlepších výsledků. Co se týče průměrných výsledků indikátorů kvality, tak zde se nedá přesně říci, v čí prospěch hovoří, protože výsledky se liší pouze nepatrně (kromě průměrných hodnot pro senzitivitu, která hovoří ve prospěch algoritmu s prahovou hodnotou kruhovitosti 0,50).

Tabulka 16: Výsledky objektivního posouzení kvality pro algoritmus s prahem 0,50

Snímek	SSIM	MSE	Korelační koeficient	Senzitivita	Specifická	Přesnost
Test 1	0,989	151,4	0,800	0,623	0,996	0,994
Test 2	0,871	4419,4	0,313	0,101	0,991	0,938
Test 3	0,917	2676,0	0,463	0,357	0,972	0,950
Test 4	0,894	2900,7	0,590	0,354	0,984	0,948
Test 5	0,934	1681,4	0,666	0,443	0,991	0,969
Test 6	0,932	1766,9	0,662	0,440	0,991	0,968
Test 7	0,812	5186,1	0,424	0,199	0,984	0,921
Test 8	0,816	6255,1	0,454	0,189	0,989	0,907
Test 9	0,903	2959,3	0,461	0,280	0,976	0,946
Test 10	0,905	2881,1	0,437	0,298	0,973	0,947
Test 11	0,932	1676,9	0,578	0,320	0,990	0,969
Test 12	0,919	2120,8	0,554	0,365	0,979	0,958
Test 13	0,869	3982,0	0,496	0,222	0,989	0,939
Test 14	0,883	3014,5	0,621	0,404	0,980	0,944
Test 15	0,890	2780,6	0,684	0,480	0,977	0,944
Test 16	0,869	3836,3	0,544	0,347	0,974	0,931
Test 17	0,855	4826,3	0,450	0,193	0,989	0,928
Test 18	0,962	1474,8	0,087	0,023	0,997	0,980
Test 19	0,897	3067,8	0,451	0,303	0,971	0,943
Test 20	0,971	696,0	0,637	0,360	0,995	0,986
Test 21	0,972	648,9	0,673	0,376	0,996	0,987
Test 22	0,980	375,2	0,781	0,533	0,996	0,990
Test 23	0,938	1458,7	0,631	0,467	0,982	0,968
Test 24	0,903	3227,3	0,408	0,154	0,990	0,949
Test 25	0,922	2426,6	0,511	0,245	0,991	0,960
Test 26	0,926	2043,9	0,526	0,362	0,986	0,964
Test 27	0,940	2121,0	0,335	0,163	0,922	0,968
Test 28	0,901	3070,6	0,450	0,204	0,988	0,950
Test 29	0,9886	3418,9	0,425	0,151	0,996	0,951
Test 30	0,959	1156,3	0,525	0,312	0,991	0,978
Test 31	0,921	1885,2	0,681	0,484	0,985	0,963
Test 32	0,915	2719,2	0,476	0,365	0,974	0,951
Test 33	0,948	1035,7	0,767	0,548	0,988	0,974
Test 34	0,935	1893,6	0,610	0,349	0,990	0,966

Test 35	0,989	207,6	0,528	0,537	0,994	0,993
Test 36	0,991	168,6	0,766	0,468	0,998	0,996
Test 37	0,979	445,2	0,718	0,442	0,998	0,992
Test 38	0,980	834,7	0,233	0,063	0,998	0,987
Průměrná hodnota	0,924	2302,4	0,537	0,330	0,986	0,960

Tabulka 17: Výsledky objektivního posouzení kvality pro algoritmus s prahem 0,70

Snímek	SSIM	MSE	Korelační koeficient	Senzitivita	Specifická	Přesnost
Test 1	0,991	121,0	0,837	0,623	0,997	0,995
Test 2	0,876	4296,1	0,343	0,094	0,996	0,941
Test 3	0,935	1794,1	0,611	0,357	0,988	0,966
Test 4	0,886	3722,1	0,419	0,176	0,989	0,943
Test 5	0,929	2172,4	0,536	0,288	0,992	0,964
Test 6	0,926	2265,2	0,534	0,286	0,992	0,964
Test 7	0,853	5170,4	0,425	0,170	0,993	0,927
Test 8	0,813	6865,3	0,370	0,136	0,993	0,905
Test 9	0,913	2769,7	0,452	0,181	0,991	0,956
Test 10	0,921	2485,8	0,460	0,177	0,991	0,960
Test 11	0,930	2206,0	0,361	0,124	0,995	0,968
Test 12	0,928	1924,4	0,580	0,323	0,990	0,967
Test 13	0,869	4111,5	0,472	0,205	0,989	0,938
Test 14	0,878	4012,7	0,438	0,199	0,994	0,945
Test 15	0,880	4035,5	0,472	0,209	0,992	0,940
Test 16	0,866	4671,2	0,376	0,122	0,993	0,934
Test 17	0,878	5597,0	0,296	0,085	0,995	0,925
Test 18	0,962	1474,8	0,087	0,024	0,997	0,980
Test 19	0,914	2681,9	0,469	0,181	0,991	0,957
Test 20	0,967	986,0	0,441	0,219	0,993	0,982
Test 21	0,971	854,6	0,531	0,226	0,997	0,986
Test 22	0,979	498,1	0,694	0,429	0,997	0,991
Test 23	0,946	1452,6	0,597	0,337	0,992	0,974
Test 24	0,905	3538,1	0,299	0,070	0,994	0,949
Test 25	0,924	2644,0	0,443	0,157	0,996	0,961
Test 26	0,941	1693,0	0,605	0,319	0,996	0,973
Test 27	0,943	2059,0	0,353	0,163	0,994	0,969
Test 28	0,902	3383,5	0,348	0,106	0,993	0,950
Test 29	0,896	3916,8	0,263	0,055	0,998	0,948
Test 30	0,963	1012,4	0,582	0,312	0,994	0,981
Test 31	0,919	2399,3	0,595	0,289	0,992	0,961

Test 32	0,634	1837,2	0,628	0,365	0,990	0,966
Test 33	0,950	1030,5	0,767	0,533	0,990	0,975
Test 34	0,935	1893,6	0,610	0,349	0,990	0,966
Test 35	0,992	150,6	0,592	0,537	0,995	0,995
Test 36	0,991	168,6	0,766	0,468	0,998	0,996
Test 37	0,976	697,8	0,493	0,205	0,999	0,990
Test 38	0,980	834,7	0,233	0,063	0,998	0,987
Průměrná hodnota	0,917	2458,6	0,484	0,241	0,994	0,963

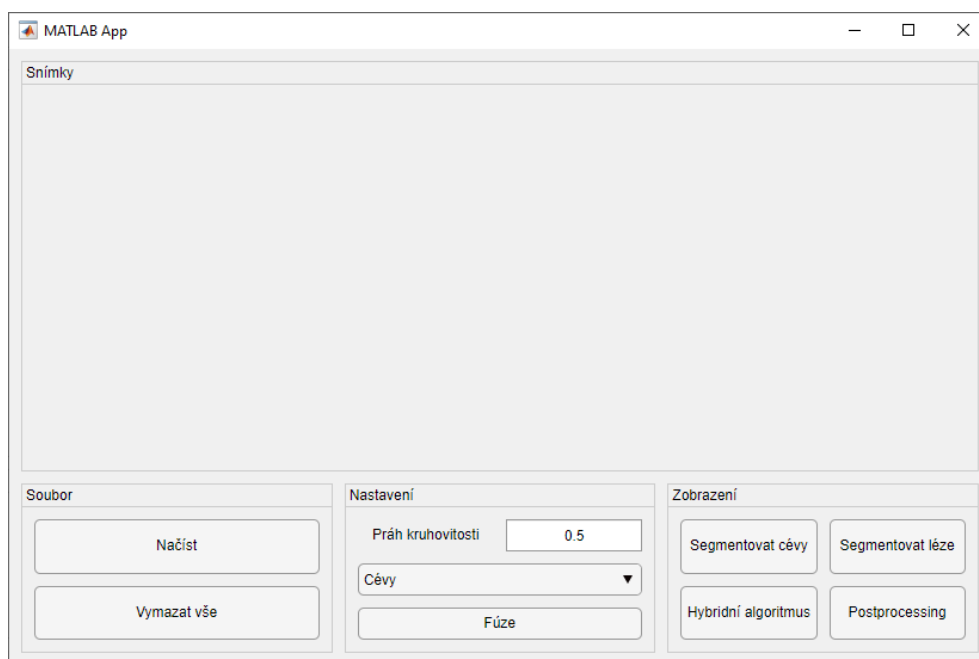
Tabulka 18: Průměrné hodnoty parametrů a indikátorů kvality všech tří testovaných prahů

Nastavený prah	SSIM	MSE	Korelační koeficient	Senzitivita	Specificita	Přesnost
0,50	0,924	2302,4	0,537	0,330	0,986	0,960
0,60	0,925	2262,2	0,541	0,309	0,991	0,963
0,70	0,917	2458,6	0,484	0,241	0,994	0,963

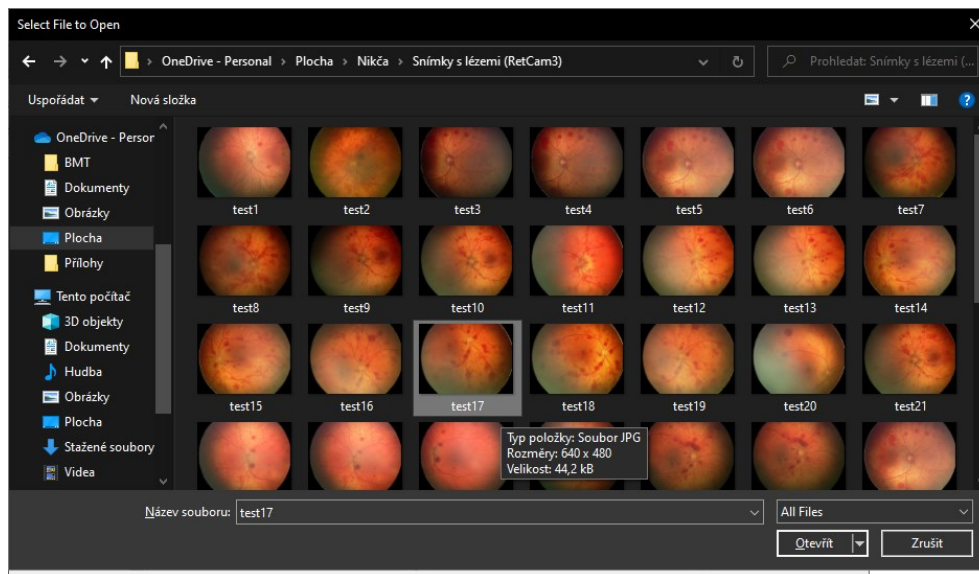
8 Tvorba softwarového prostředí

Posledním bodem zadání této diplomové práce je tvorba graficko-uživatelského rozhraní (GUI). Hlavním cílem je vytvořit dostatečně intuitivní a snadno ovladatelné prostředí pro automatizovanou detekci a segmentaci retinálních lézí u onemocnění ROP. Pro tvorbu GUI bylo použito interaktivní vývojové prostředí pro vytváření aplikací v MATLABu, tzv. App Designer. Na obrázku níže (Obrázek 59) je zobrazeno GUI po jeho spuštění.

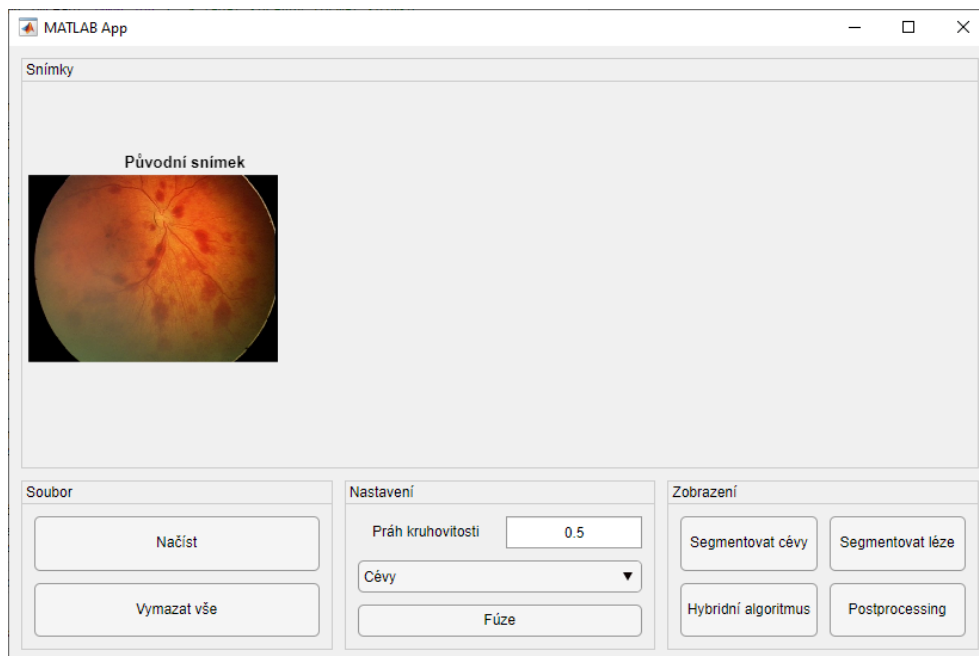
Architektura okna je rozdělena na dvě části. Vrchní část slouží pro vykreslování snímků v tomto pořadí – původní, segmentovaný a fúzovaný. Spodní část představuje ovládací panel, který se skládá ze tří bloků – soubor, nastavení a zobrazení. Pro načtení retinálního snímku stiskneme tlačítko „Načíst“. Po stisku tohoto tlačítka se zobrazí vyskakovací okno, které nám umožní procházet složky a soubory a vybrat si námi požadovaný snímek (viz Obrázek 60). Jakmile najdeme hledaný snímek, stiskneme tlačítko „Otevřít“ a snímek se zobrazí v GUI (viz Obrázek 61).



Obrázek 59: Graficko-uživatelské rozhraní navrhnuté v App Designeru

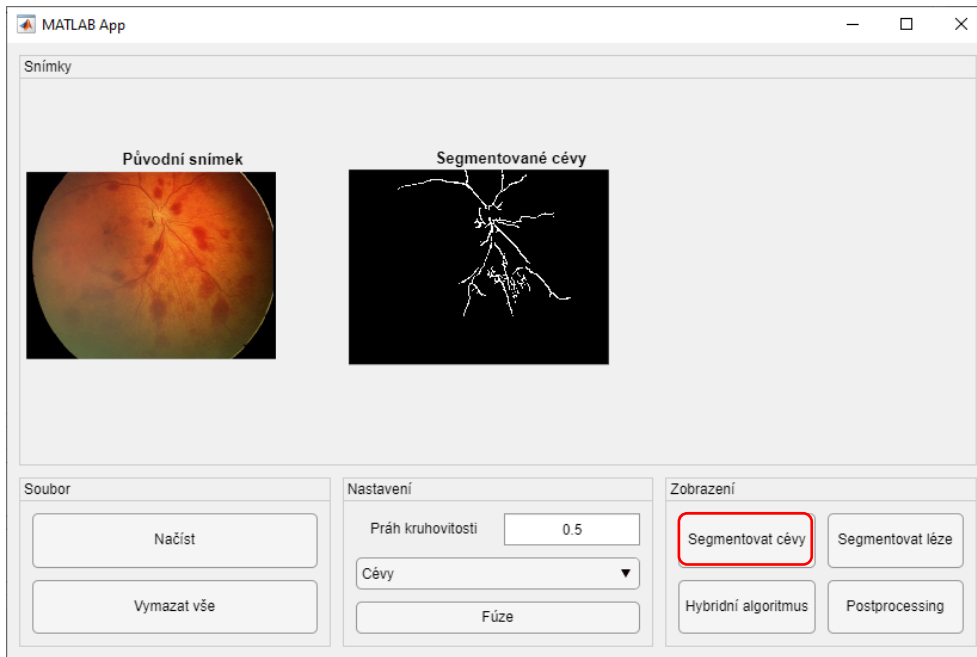


Obrázek 60: Vyskakovací okno pro výběr snímku

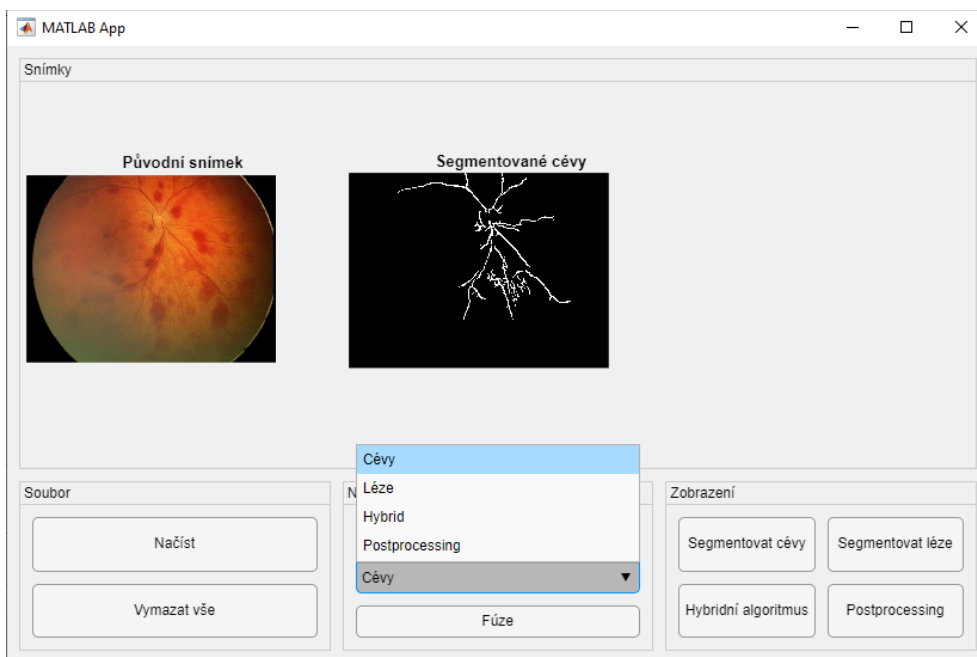


Obrázek 61: Otevření požadovaného snímku v aplikaci

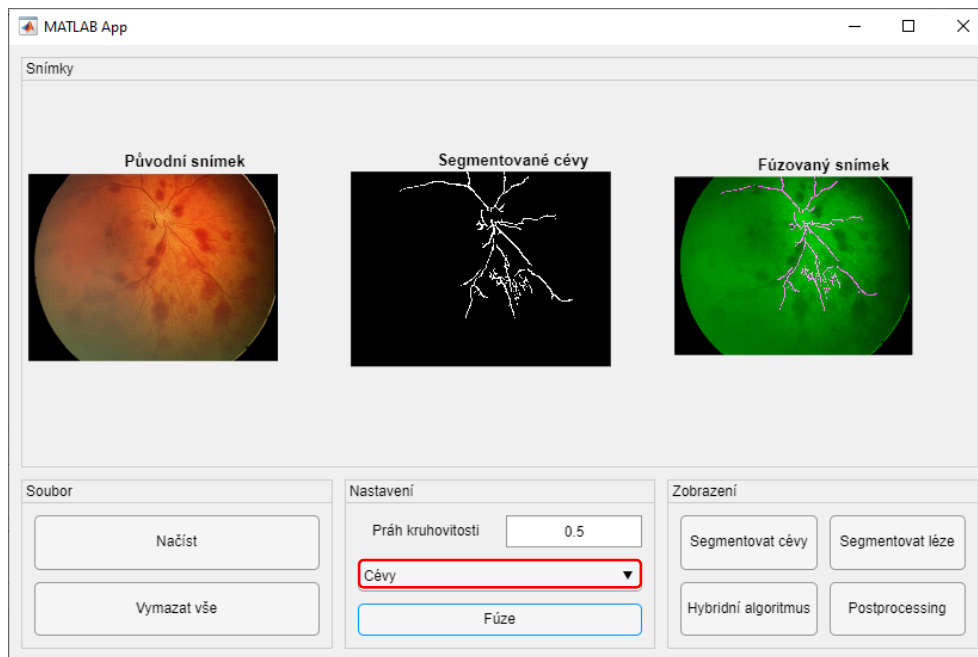
Poté se přesuneme k bloku pro nastavení a zobrazení. Jestliže chceme zobrazit výsledek hybridního algoritmu, je potřeba nejdříve zobrazit výsledek pro segmentaci cév a segmentaci lézí. Po stisknutí tlačítka „Segmentovat cévy“ se nám uprostřed horní části zobrazí výsledné segmentované cévní řečiště (Obrázek 62). Pro co nejlepší vizuální zobrazení si v bloku pro nastavení vybereme fúzi cév (Obrázek 63) a stiskneme tlačítko „Fúze“. Výsledkem tohoto tlačítka je zobrazení fúzovaného snímku, který kombinuje snímek původní a segmentovaný (Obrázek 64).



Obrázek 62: Zobrazení segmentovaného cévního řečiště

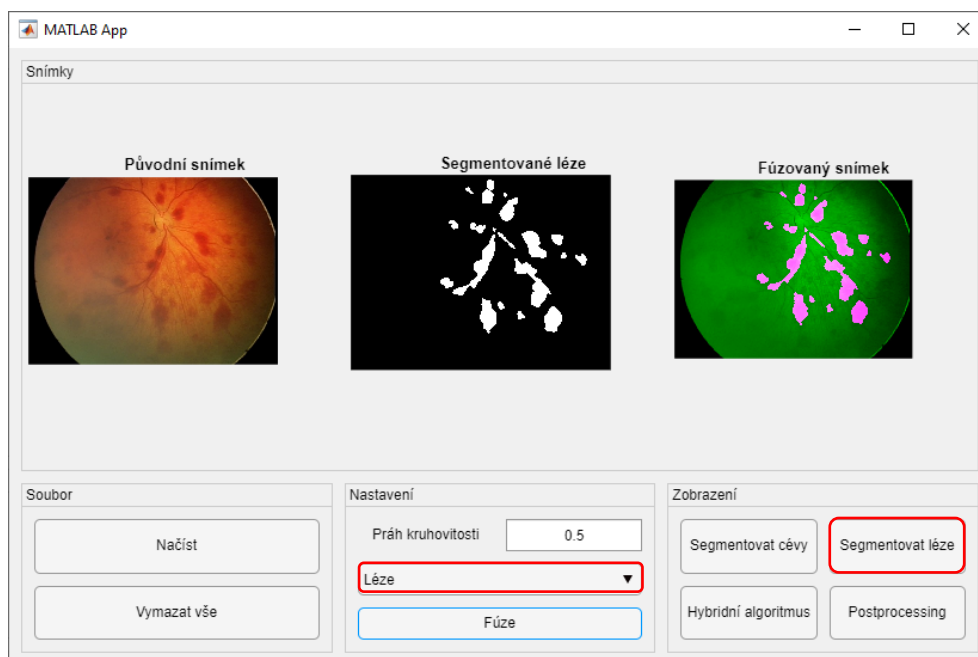


Obrázek 63: Výběr z možností pro fúzi obrazu

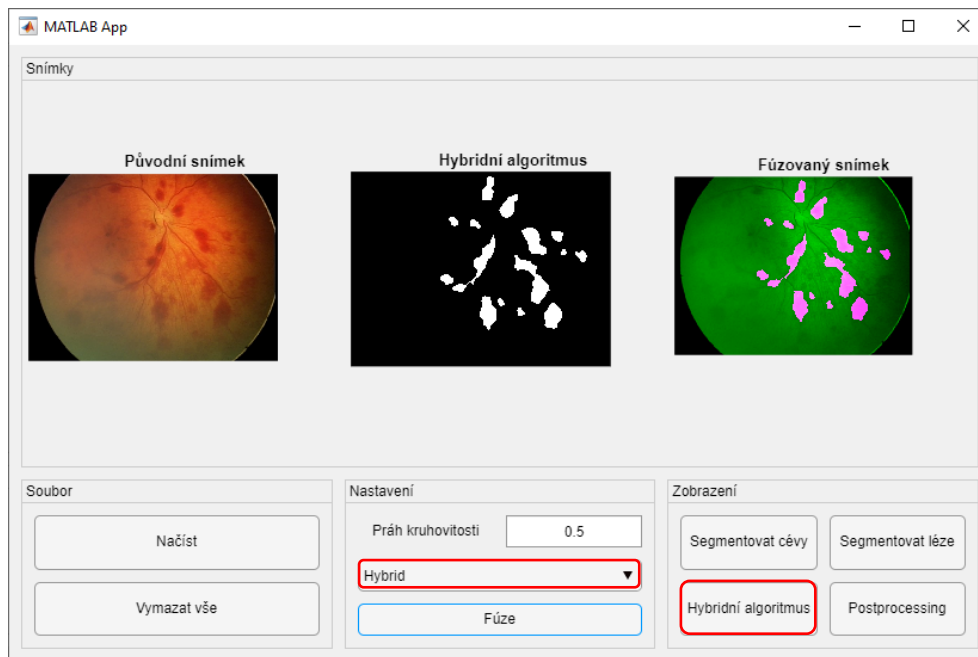


Obrázek 64: Zobrazení fúzovaného snímku pro segmentaci cév

Stejným způsobem budeme postupovat i u tlačítka pro segmentaci retinálních lézí a hybridního algoritmu (viz Obrázek 65 a Obrázek 66).

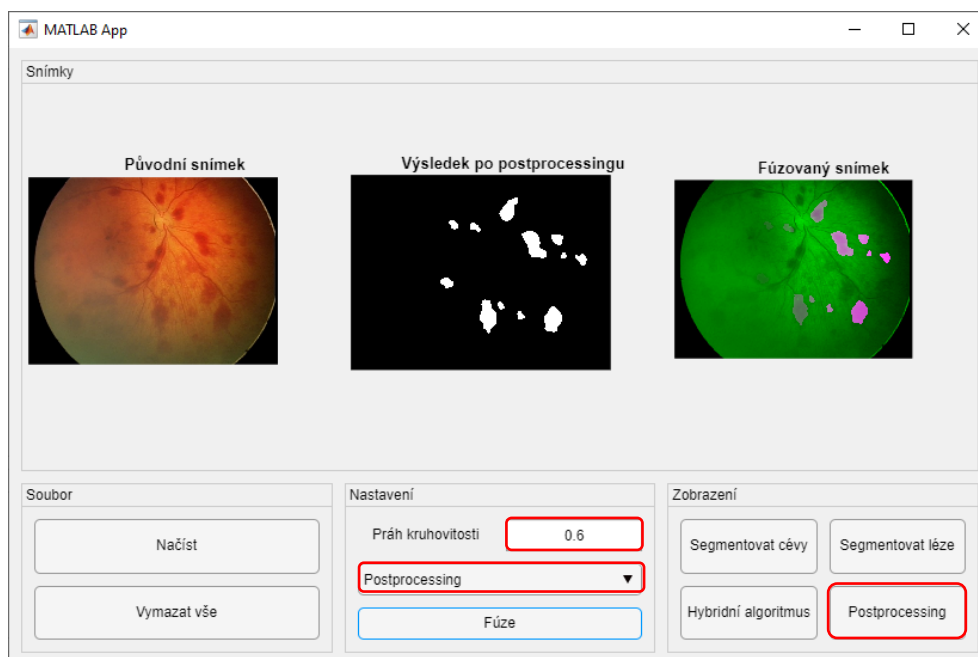


Obrázek 65: Výsledné zobrazení pro segmentaci retinálních lézí




Obrázek 66: Výsledné zobrazení hybridního algoritmu kombinující segmentaci cév a segmentaci lézí

Poté se dostáváme k zobrazení výsledného snímku po postprocessingu, který je založený na kruhovitosti. S tímto bodem souvisí i možnost nastavení prahové hodnoty, kterou je možné nastavit od 0 do 1. Defaultně byla tato prahová hodnota nastavena na 0,5. Jelikož navrhovaný algoritmus dosahoval při objektivní analýze nejlepších výsledků s prahem 0,6, byl i zde pro ukázkou nastaven tento práh (viz obrázek 67). Ať už je prahová hodnota nastavena jakkoliv, tak při stisknutí tlačítka „Postprocessing“ se vykreslí jak výsledek po postprocessingu v aplikaci, tak se objeví i vyskakovací okno s mírou kruhovitosti pro všechny objekty po implementaci hybridního algoritmu (Obrázek 68). Toto vyskakovací okno se zde objevuje proto, aby měl uživatel představu o tom, jak práh kruhovitosti nastavit (jakou hodnotu zvolit).



Obrázek 67: Výsledné zobrazení po postprocesingu s hodnotou prahu 0,6



Obrázek 68: Vyskakovací okno s mírou kruhovitosti pro každý objekt zvlášť

Závěr

Hlavním cílem této diplomové práce bylo navrhnout hybridní algoritmus pro extrakci retinálních lézí z retinálních obrazových dat. Algoritmus byl aplikován na snímky předčasně narozených dětí poskytnutých Oční klinikou Fakultní nemocnice v Ostravě.

Před návrhem algoritmu byla vypracována rešerše na téma detekce retinálních lézí s využitím prvků umělé inteligence. Na toto téma bylo napsáno již nepřehledné množství publikací a odborných prací, avšak valná většina z nich se zabývá diabetickou retinopatií, což s tématem této diplomové práce nekoreluje, jelikož zde bylo nutné zaměřit se na retinopatii nedonošených (ROP).

Obrazová data použitá v rámci řešení této práce byla pořízena systémem RetCam3 s rozlišením 640 x 480 pixelů. Z celkového datasetu obsahujícího 835 snímků, na nichž se vyskytují retinální léze, bylo vybráno pouze 38 dostatečně kvalitních snímků, které byly dále využity pro řešení této práce. Výběr tak malého testovacího datasetu byl výsledkem nedostatečné kvality snímků v poskytnutém datasetu, neboť jak již bylo zmíněno, data byla pořízena od předčasně narozených dětí a získat dostatečně kvalitní data od pacientů starých jen několik málo dní bývá značně obtížné i pro zkušené oftalmology. Pro segmentaci retinálních lézí byl navrhnout hybridní algoritmus kombinující dva segmentační algoritmy pro dosažení co možná nejlepších výsledků společně s extrakcí příznaků pro kruhovitost.

V další části byly výsledky algoritmu objektivně zhodnoceny. Aby však bylo možné provést objektivní analýzu, bylo potřeba vytvořit zlaté standardy, vůči kterým byly výsledky navrhovaného algoritmu porovnávány. Pro objektivní posouzení kvality byly využity tři objektivizační parametry (strukturní index podobnosti, střední kvadratická chyba a korelační koeficient) a tři indikátory kvality (senzitivita, specifická a přesnost). Velkou limitací algoritmu je jeho nestálost v rozsahu segmentace. V určitých případech dokázal algoritmus detekovat umístění lézí správně, ale už je nedokázal detekovat v plném rozsahu. Na druhou stranu v mnoha případech nebyly léze algoritmem vůbec detekovány. Právě z toho důvodu byla samotná objektivní analýza provedena ve dvou krocích. V rámci prvního kroku byly výsledky navrhovaného algoritmu porovnány se zlatými standardy, které byly vytvořeny na základě těchto výsledků. To znamená, že tyto zlaté standardy obsahovaly pouze ty retinální léze, které dokázal vytvořený algoritmus detekovat. Ve druhém kroku byly výsledky algoritmu porovnány se zlatými standardy, které již obsahují všechny léze detekovatelné okem pozorovatele. Neschopnost detekce retinálních lézí může být podmíněna jak nedostatečnou kvalitou testovaných snímků, tak i možným nesprávným přístupem v některé části algoritmu. Pro zjištění nejlepší prahové hodnoty pro kruhovitost byla provedena komparativní analýza, která porovnávala výsledky tří různých prahových hodnot, konkrétně 0,5, 0,6 a 0,7. Na základě tohoto testování dosahoval práh s hodnotou 0,6 nejlepších výsledků pro všechny tři objektivizační parametry, kdežto u indikátoru kvality nebyly rozdíly ve výsledných průměrných hodnotách pro tyto tři prahy nijak signifikantní.

Posledním bodem zadání byla tvorba graficko-uživatelského rozhraní. Značnou výhodou tohoto navrženého prostředí byla možnost volby prahové hodnoty pro kruhovitost na takovou hodnotu, jakou si zvolil sám uživatel.

Další vývoj této diplomové práce by se mohl zaměřit na lepší implementaci hybridního algoritmu co se týče subtrakce výsledků získaných po segmentaci obou algoritmů, protože touto subtrakcí došlo i k odečtení částí lézí, které poté ztratily svůj kruhovitý charakter.

Seznam použité literatury

- [1] HLOŽÁNEK, Martin. *Přístrojová technika v oftalmologii* [online]. Praha: ART et FACT, 2006 [cit. 2021-9-1]. ISBN 80-902160-9-9.
- [2] GALUSZKA, Adriana. *SW pro automatické modelování a evaluaci retinálních lézí*. Ostrava, 2019. Diplomová práce. VŠB-TUO. Vedoucí práce Ing. Jan Kubíček, Ph.D.
- [3] OČNÍ LÉKAŘ [online]. [cit. 2021-09-01]. Dostupné z: <http://ocni-lekar.info/lekarske-vykony/vysetreni-zadniho-segmentu-oka/oftalmoskopie/>
- [4] ČVANČARA, Martin. *Algoritmus pro hodnocení sítnicových obrazů*. Ostrava, 2014. Diplomová práce. VŠB-TUO. Vedoucí práce Ing. Martin Augustýnek.
- [5] HORÁKOVÁ, Zuzana. *Metody vyšetřování očního fundu přímou a nepřímou oftalmoskopií*. Olomouc, 2014. Bakalářská práce. UPOL. Vedoucí práce Mgr. Lucie Machýčková.
- [6] Zeiss [online]. [cit. 2021-9-1]. Dostupné z: <https://www.zeiss.com/meditec/int/product-portfolio/retinal-cameras/visucam-fundus-imaging.html#specifications>
- [7] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektronické přístroje 1*. Ostrava, 2013. ISBN 978-80-248-3107-7.
- [8] *Ultrasonografie* [online]. [cit. 2021-9-1]. Dostupné z: http://www.jtarchitekt.cz/lekarske_vyuziti.html
- [9] *Heidelbergh Engineering: Spectralis spirit: Build your practice* [online]. [cit. 2021-9-6]. Dostupné z: <https://business-lounge.heidelbergengineering.com/gb/en/products/spectralis-spirit/build-your-practice/>
- [10] KUCHYNKA, Pavel. *Oční lékařství*. 2. vydání. Praha: Grada Publishing, 2016. ISBN 978-80-247-5079-8.
- [11] *Oční ordinace MUDr. Stanislava Stuchlá: Převrat v diagnostice a sledování glaukomu - HRT III* [online]. [cit. 2021-9-6]. Dostupné z: <https://www.drstuchla.cz/sluzby/hrtIII/hrtIII.html>
- [12] *SPECTRALIS Imaging Platform Technical Specifications* [online]. [cit. 2021-9-6]. Dostupné z: file:///C:/Users/Niki/AppData/Local/Temp/200279-002-INT-AE18_SPECTRALIS-Technical-Data-Sheet_EN.pdf
- [13] KOUDAROVÁ, Kamila. *Strukturální vyšetřovací metody v diagnostice glaukomu*. Brno, 2009. Bakalářská práce. Masarykova univerzita. Vedoucí práce MUDr. Jarmila Kočí.
- [14] Fluorescenční angiografie. *Wikiskripta.eu* [online]. 2018 [cit. 2021-9-9]. Dostupné z: https://www.wikiskripta.eu/w/Fluorescen%C4%8Dn%C3%AD_angiografie
- [15] Fluorescenční angiografie (FAG). *Visus* [online]. [cit. 2021-9-9]. Dostupné z: <https://www.ocni-visus.cz/vysetreni/vysetreni-fag/>
- [16] Co je skenovací laserová oftalmoskopie? *Netinbag.com* [online]. [cit. 2021-9-11]. Dostupné z: <https://www.netinbag.com/cs/health/what-is-scanning-laser-ophthalmoscopy.html>
- [17] EasyScan. *SPIRIT MEDICAL* [online]. [cit. 2021-9-11]. Dostupné z: <https://www.spiritmedical.cz/cs/ocni-ambulance/retinalni-kamery-slo/easyscan.html>

- [18] KŘEŠŤANOVÁ, Alice. *Modelování sítnicového cévního systému s cílem jeho obrazové extrakce a standardizace cévní tortuozity*. Ostrava, 2018. Diplomová práce. VŠB –Technická univerzita Ostrava. Vedoucí práce Ing. Jan Kubíček, Ph.D.
- [19] VAVREČKOVÁ, Nikola. *Segmentace retinálního cévního systému na základě metody maximum principal curvature*. Ostrava, 2020. Bakalářská práce. VŠB-Technická univerzita Ostrava. Vedoucí práce Ing. Alice Křesťanová.
- [20] *RetCam3 pediatric eye imaging: Because every newborn deserves clear vision* [online]. Natus, 2016. [cit. 2021-09-11] Dostupné z: <https://www.oftis-opta.cz/wp-content/uploads/2018/05/RetCam3.pdf>
- [21] Phoenix ICON: Retinal Imaging. *Phoenix Technology Group* [online]. [cit. 2021-9-18]. Dostupné z: <https://phoenixtech.com/phoenix-icon/>
- [22] KUČERA, Jiří. Shluková analýza [online]. [cit. 2021-10-9]. Dostupné z: https://is.muni.cz/th/172767/fi_b/5739129/web/web/main.html
- [23] AGRAWAL, Shubhang. To Start with K-means Clustering. *Analytisc Vidhya* [online]. [cit. 2021-10-9]. Dostupné z: <https://medium.com/analytics-vidhya/to-start-with-k-means-clustering-1c6ee3cb840f>
- [24] KUBÍČEK, Jan. *Segmentace obrazu*. [cit. 2021-10-11]. Prezentace prezentována v: [Lékařské zobrazovací systémy II, VŠB-TU, 2021, Ostrava.]
- [25] KUBÍČEK, Jan. *Klasifikace dat a neuronové sítě*. [cit. 2021-10-11]. Prezentace prezentována v: [Lékařské zobrazovací systémy II, VŠB-TU, 2021, Ostrava.]
- [26] PRATT, Mary K. What is unsupervised learning? *SearchEnterpriseAI* [online]. [cit. 2021-10-11]. Dostupné z: <https://searchenterpriseai.techtarget.com/definition/unsupervised-learning>
- [27] POLÁCH, Michal. *Segmentace obrazu nevyvážených dat pomocí umělé inteligence* [online]. Brno, 2019 [cit. 2021-10-11]. Diplomová práce. VUT. Vedoucí práce Ing. Martin Kolařík.
- [28] Deep learning pro segmentaci obrazu. *SCIENCE mag* [online]. 5.11.2017 [cit. 2021-10-12]. Dostupné z: <https://sciencemag.cz/deep-learning-pro-segmentaci-obrazu/>
- [29] GENSURE, Rebekah H., Michael F. CHIANG a John P. CAMPBELL. Artificial intelligence for retinopathy of prematurity. *Current Opinion in Ophthalmology* [online]. 2020, 31(5), 312-317 [cit. 2021-10-28]. ISSN 1040-8738. Dostupné z: doi:10.1097/ICU.0000000000000680
- [30] BANDYOPADHYAY, Tathagata, Jan KUBICEK, Marek PENHAKER, Juraj TIMKOVIC, David OCZKA a Ondrej KREJCAR. *A Semi-Supervised Learning Approach for Automatic Segmentation of Retinal Lesions Using SURF Blob Detector and Locally Adaptive Binarization*. In: . Cham: Springer International Publishing, 2019, s. 311-323. ISBN 978-3-030-14802-7.
- [31] SCRUGGS, Brittni A., R. V. Paul CHAN, Jayashree KALPATHY-CRAMER, Michael F. CHIANG a J. Peter CAMPBELL. Artificial Intelligence in Retinopathy of Prematurity Diagnosis. *Translational Vision Science & Technology* [online]. 2020, 9(2) [cit. 2021-11-04]. ISSN 2164-2591. Dostupné z: doi:10.1167/tvst.9.2.5
- [32] RAMACHANDRAN, Sivakumar, Punnakadan NIYAS, Anand VINEKAR a Renu JOHN. A deep learning framework for the detection of Plus disease in retinal fundus images of preterm infants.

Biocybernetics and Biomedical Engineering [online]. 2021, 41(2), 362-375 [cit. 2021-10-29]. ISSN 02085216. Dostupné z: doi: 10.1016/j.bbe.2021.02.005

[33] WANG, Ji, Jie JI, Mingzhi ZHANG, et al. Automated Explainable Multidimensional Deep Learning Platform of Retinal Images for Retinopathy of Prematurity Screening. JAMA Network Open [online]. 2021, 4(5) [cit. 2021-10-29]. ISSN 2574-3805. Dostupné z: doi:10.1001/jamanetworkopen.2021.8758

[34] TONG, Yan, Wei LU, Qin-qin DENG, Changzheng CHEN a Yin SHEN. Automated identification of retinopathy of prematurity by image-based deep learning. Eye and Vision [online]. 2020, 7(1) [cit. 2021-10-31]. ISSN 2326-0254. Dostupné z: doi:10.1186/s40662-020-00206-2

[35] HUANG, Yo-Ping, Haobijam BASANTA, Eugene Yu-Chuan KANG, et al. Automated detection of early-stage ROP using a deep convolutional neural network. British Journal of Ophthalmology [online]. , bjophthalmol-2020-316526 [cit. 2021-11-02]. ISSN 0007-1161. Dostupné z: doi:10.1136/bjophthalmol-2020-316526

[36] YILDIZ, Veysi M., Peng TIAN, Ilkay YILDIZ, et al. Plus Disease in Retinopathy of Prematurity: Convolutional Neural Network Performance Using a Combined Neural Network and Feature Extraction Approach. Translational Vision Science & Technology [online]. 2020, 9(2) [cit. 2021-11-03]. ISSN 2164-2591. Dostupné z: doi:10.1167/tvst.9.2.10

[37] LEI, Baiying, Xianlu ZENG, Shan HUANG, et al. Automated detection of retinopathy of prematurity by deep attention network. Multimedia Tools and Applications [online]. [cit. 2021-11-04]. ISSN 1380-7501. Dostupné z: doi:10.1007/s11042-021-11208-0

[38] TAN, Zachary, Samantha SIMKIN, Connie LAI a Shuan DAI. Deep Learning Algorithm for Automated Diagnosis of Retinopathy of Prematurity Plus Disease. Translational Vision Science & Technology [online]. 2019, 8(6) [cit. 2021-11-05]. ISSN 2164-2591. Dostupné z: doi:10.1167/tvst.8.6.23

[39] MAO, Jianbo, Yuhao LUO, Kun CHEN, et al. New grading criterion for retinal haemorrhages in term newborns based on deep convolutional neural networks. *Clinical & Experimental Ophthalmology* [online]. 2020, 48(2), 220-229 [cit. 2022-01-14]. ISSN 1442-6404. Dostupné z: doi:10.1111/ceo.13670

[40] MUSTAFA, Wan Azani a Mohamed Mydin M. ABDUL KADER. *Binarization of Document Images: A Comprehensive Review*. Journal of Physics: Conference Series [online]. 2018, 1019 [cit. 2022-02-05]. ISSN 1742-6588. Dostupné z: doi:10.1088/1742-6596/1019/1/012023

[41] Identifying Round Objects. *MathWorks* [online]. [cit. 2022-02-24]. Dostupné z: <https://www.mathworks.com/help/images/identifying-round-objects.html>

[42] *Keeler Accutome Connect: For all of your ophthalmic needs* [online]. [cit. 2022-04-03]. Dostupné z: <https://www.spiritmedical.cz/uploads/pdf/keeler-accutome-connect-ultrazvuky.pdf>

[43] YANOFF, Myron a Jay S. DUKER. *Ophthalmology: Fifth Edition* [online]. ELSEVIER, 2019 [cit. 2022-04-20]. ISBN 978-0-323-52819-1. Dostupné z: https://books.google.cz/books?hl=en&lr=&id=34toDwAAQBAJ&oi=fnd&pg=PP1&dq=myron+yanoff+ophthalmology&ots=xo8fDwctve&sig=Y0Y-HdtwjkAJPsIXBoP-xlc1yjs&redir_esc=y#v=onepage&q=myron%20yanoff%20ophthalmology&f=false

[44] RetCam Envision™ ophthalmic imaging system. *Natus* [online]. [cit. 2022-04-20]. Dostupné z: <https://newborncare.natus.com/products-services/eye-imaging/retcam-envision>

Seznam příloh

Příloha I

Příloha v IS Edison