



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV INTELIGENTNÍCH SYSTÉMŮ

DEPARTMENT OF INTELLIGENT SYSTEMS

DETEKCE PATOLOGIÍ NA SNÍMCÍCH SÍTNICE OKA

PATHOLOGIES DETECTION IN RETINAL IMAGES

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

DAVID HURTA

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. ANDRII KAVETSKYI

BRNO 2022

Zadání bakalářské práce



Student: **Hurta David**
Program: Informační technologie
Název: **Detekce patologií na snímcích sítnice oka**
Pathologies Detection in Retinal Images
Kategorie: Bioinformatika

Zadání:

1. Prostudujte literaturu týkající se sítnice lidského oka a jeho onemocnění. Prostudujte detekci onemocnění na snímcích sítnice oka.
2. Navrhněte vlastní algoritmus pro detekci exsudátů a mikroaneuryzmat na snímcích sítnice lidského oka.
3. Implementujte algoritmus z předchozího bodu, otestujte jeho výkonnost a přesnost.
4. Shrňte dosažené výsledky, navrhněte možná zlepšení pro budoucí práci.

Literatura:

- H. Jelinek and M. Cree. Automated Image Detection of Retinal Pathology, 2009.
- S. E. Zohora, S. Chakraborty, A. M. Khan and N. Dey. Detection of Exudates in Diabetic Retinopathy: A Review. *International Conference on Electrical, Electronics, and Optimization Techniques*, 2016.
- A.P. Schachat. *Ryan's Retina*. Sixth edition. Edinburgh; New York: Elsevier, 2018.
- V. Mayya, S. S. Kamath and U. Kulkarni. Automated Microaneurysms Detection for Early Diagnosis of Diabetic Retinopathy: A Comprehensive Review. *Computer Methods and Programs in Biomedicine*, 2021.

Pro udělení zápočtu za první semestr je požadováno:

- Splnění bodů 1 a 2.

Podrobné závazné pokyny pro vypracování práce viz <https://www.fit.vut.cz/study/theses/>

Vedoucí práce: **Kavetskyi Andrii**
Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.
Datum zadání: 1. listopadu 2021
Datum odevzdání: 11. května 2022
Datum schválení: 3. listopadu 2021

Abstrakt

Cílem této práce je návrh a implementace algoritmu detekce mikroaneuryzmat, tvrdých exsudátů a měkkých exsudátů na barevných snímcích sítnice. Byl navržen algoritmus detekce objektů na základě hlubokého učení. Byla použita architektura Faster R-CNN s příznakovou pyramidovou sítí a předem vyučenou reziduální sítí společně s různými metodami transformace dat. Bylo využito celkově šesti datových sad snímků sítnic k trénování, ověřování a testování modelů. Vyučené modely dosáhly během testování hodnoty 0.46 střední průměrné přesnosti (mAP) při detekci mikroaneuryzmat a hodnoty 0.48 mAP během detekce exsudátů. Výsledné modely byly porovnány s publikovanými články a umožňují s chvályhodnou přesností detekovat dané patologie.

Abstract

The main goal of this work is to design and implement an algorithm for the detection of microaneurysms, hard exudates, and soft exudates on color fundus images. An algorithm for detecting objects based on deep learning has been proposed. The Faster R-CNN architecture with a feature pyramid network and a pre-pretrained residual network was used together with various data transformation methods. A total of six retinal image datasets were used to train, validate and test the models. The trained models achieved 0.46 mean average accuracy (mAP) in microaneurysm detection and 0.48 mAP in exudates detection during testing. The resulting models have been compared with published articles and make it possible to detect given pathologies with commendable accuracy.

Klíčová slova

detekce patologií sítnice, barevné snímky sítnice, mikroaneuryzmata, exsudáty, tvrdé exsudáty, měkké exsudáty, vatovitá ložiska, hluboké učení, Faster R-CNN, předem vyučená síť, příznaková pyramidová síť, průměrná přesnost

Keywords

retinal pathology detection, color fundus images, microaneurysms, exudates, hard exudates, soft exudates, cotton wool spots, deep learning, Faster R-CNN, pretrained network, feature pyramid network, average precision

Citace

HURTA, David. *Detekce patologií na snímcích sítnice oka*. Brno, 2022. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Andrii Kavetskyi

Detekce patologií na snímcích sítnice oka

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana Ing. Andriiho Kavetskyiho. Uvedl jsem všechny literární prameny, publikace a další zdroje, ze kterých jsem čerpal.

.....

David Hurta
9. května 2022

Poděkování

Rád bych poděkoval Ing. Andriimu Kavetskyimu za odborné konzultace, cenné připomínky a nápomocné rady během vedení této práce a za jeho trpělivý a pozitivní přístup.

Obsah

1	Úvod	2
2	Lidské oko	4
2.1	Anatomie oční koule	4
2.2	Zobrazování a snímání sítnice	8
2.3	Onemocnění sítnice	11
3	Metody detekce patologií na snímcích sítnice	16
3.1	Metody předzpracování snímků sítnice	16
3.2	Metody detekce mikroaneuryzmat	18
3.3	Metody detekce exsudátů	20
4	Datové sady snímků sítnic	21
5	Návrh algoritmu detekce patologií na snímcích sítnice	24
5.1	Datové sady a jejich zpracování	25
5.2	Předzpracování	25
5.3	System detekce objektů	27
6	Implementace	31
6.1	Základní struktura implementace	31
6.2	Zpracování anotačních souborů	32
6.3	Předzpracování dat	34
6.4	System detekce objektů a jeho trénování	35
6.5	Měření metrik	37
6.6	Použité nástroje	37
7	Testování a vyhodnocení algoritmu	38
7.1	Analýza ohraničujících boxů	38
7.2	Metriky hodnocení algoritmů detekce objektů	42
7.3	Vyhodnocení algoritmu	43
8	Závěr	52
	Literatura	53
A	Obsah paměťového média	59

Kapitola 1

Úvod

Diabetes mellitus, úplavice cukrová, rovněž známější pod pojmem cukrovka. Tento název představuje skupinu chronických metabolických onemocnění, jež se rozšiřují v dnešní době vzhledem k modernímu životnímu stylu. Tyto onemocnění jsou schopné závažně ovlivnit život jedince. Mezi pozdní komplikace úplavice cukrové patří taktéž diabetická retinopatie. Toto onemocnění, jestliže neléčené, je schopné zapříčinit zhoršení až ztrátu zraku jedince. Je tedy velmi důležité případnou diabetickou retinopatii u pacienta odhalit co nejdříve, aby se zastavilo zhoršování zraku a v horších případech zamezila ztráta vidění. Diabetickou retinopatii lze identifikovat u jedince detekováním jejich příznaků. Mezi tyto příznaky patří mikroaneuryzmata a exsudáty, avšak příznaků existuje více a jejich výskyt záleží na aktuální fázi diabetické retinopatie. Tato práce se zaměřuje právě na detekci mikroaneuryzmat a exsudátů na snímcích sítnice.

Automatizované detekování patologií na snímcích sítnice zvyšuje pravděpodobnost objevení těchto patologií u daného jedince. A tím zvyšuje pravděpodobnost, že správná diagnostika pacienta je zjištěna co nejdříve. Manuální hledání patologií na snímcích sítnice je zdoluhavá práce a počet odborníků v daném oboru je omezen. V chudších částech světa je až velmi omezen. Automatizovaná detekce je schopná pomoci odborníkům při jejich práci a potenciálně až nahradit práci odborníka s určitou přesností.

Potenciál automatizované detekce patologií na snímcích sítnice je už znám desítky let. Metody detekce určitých patologií se neustále vyvíjejí a přichází se na nové způsoby detekce společně s pokrokem výkonu počítače. V dnešní době se převážně experimentuje s metodami detekce, které jsou založené na strojovém učení, avšak i detekce založené na jiných metodách oznamují chvályhodné výsledky.

V této oblasti detekce obrazu je tedy velmi velký potenciál pomoci lidem kolem nás. Ať už specializovaným odborníkům ve zjednodušení jejich práce, tak také obyčejným lidem ve zlepšení jejich zdraví. Už jenom samotná automatizovaná detekce mikroaneuryzmat a exsudátů může pomoci specialistům nalézt exsudáty, které by normálně přehlédli. Nebo může do jisté míry nahradit specialisty v chudších částech světa, jelikož vzdělání a výškolení takového odborníka je časově a finančně náročné.

Cílem práce je navrhnutí a implementace vlastního algoritmu pro detekci mikroaneuryzmat a exsudátů na snímcích sítnice s pomocí veřejně dostupných vědeckých článků zabývajících se podobným tématem. Součástí práce je taktéž testování a vyhodnocení implementovaného algoritmu pomocí metrik používaných k hodnocení algoritmů detekce obrazu a následné porovnání výsledků s algoritmy již implementovanými odborníky ve světě.

V následující kapitole 2 je popsána anatomie oční koule, způsoby snímání sítnice a podrobněji vysvětleny patologie mikroaneuryzmata, tvrdé exsudáty a měkké exsudáty. Ka-

pitola 3 se zabývá metodami již použitými v praxi a slouží jako inspirace k navrhnutí algoritmu detekce. Kapitola 4 popisuje použité datové sady snímků sítnic. Kapitola 5 popisuje návrh algoritmu detekce patologií na snímcích sítnice založeném na hlubokém učení. Další kapitola 6 se zabývá způsobem implementace navrženého algoritmu a popisuje základní či zajímavé pasáže implementace. Výsledné vyhodnocení modelů a porovnání modelů s publikovanými články se nachází v kapitole 7.

Kapitola 2

Lidské oko

Pro tvorbu návrhu a následné implementace automatizované detekce mikroaneuryzmat a exsudátů na snímcích sítnice je patřičné zmínit pár základních údajů týkajících se této oblasti.

Podkapitola 2.1 se zaměřuje na popsání základních částí oční koule pro získání potřebných fundamentálních znalostí pro rozpoznání a pochopení určitých částí lidského oka, které se dělí na tři vrstvy. Důraz je taktéž kladen na samotnou sítnici a její hlavní části viditelné na snímcích sítnice


Podkapitola 2.2 se zabývá popsáním metod zobrazení sítnice a jejího snímání. Popisuje nejčastější metody snímání sítnice a principy, na kterých jsou založeny tyto metody založeny.

Podkapitola 2.3 popisuje základní charakteristiky detekovaných patologií. Taktéž popisuje jejich vizuální vzhled na snímcích sítnice, jejich důvody vzniku, jejich následky a další patřičné informace vhodné brát v potaz při návrhu samotného algoritmu pro jejich detekci.

2.1 Anatomie oční koule

Zrak je nejdůležitější smysl člověka. Zprostředkovává mu převážnou většinu informací týkajících se reality kolem něj. Člověk pomocí zraku vnímá kolem 80% veškerých informací ze světa kolem něj. Od vnímání světla, rozeznání barev, tvarů až po adaptaci pro vidění ve tmě. Taktéž se podílí na udržování rovnováhy a orientaci v prostoru. Zrak člověku obstarává zrakové ústrojí, které reaguje na elektromagnetické vlnění. Orgánem zraku je oko. Oko se skládá z oční koule a přídatných očních orgánů.

Hlavní částí je oční koule (latinsky *bulbus oculi*), jež je velice komplexní a vysoce specializovaný orgán. Oční koule je umístěna v obličejové části lebky zvaném dutina očnícová. Její tvar je přibližně kulovitý, délka oční koule je přibližně 2,5 cm a její šířka kolem 2,3 cm. Nachází se na tukovém polštářku chránící oční kouli před nárazy. Oční koule se skládá ze tří vrstev. Skládá se ze zevní vazivové, střední a vnitřní vrstvy. Jednotlivé dílčí části oční koule jsou zobrazeny na obrázku 2.1. Tato podkapitola je převzata ze [8], [23] a [28], jestliže není zmíněno jinak.



Obrázek 2.1: Průřez oční koule [41].

2.1.1 Zevní vazivová vrstva

Zevní vazivová vrstva oční koule je složena z bělimy a rohovky.

Bělima (latinsky *sclera*) zaujímá kolem 80% povrchu oční koule. Bělima představuje pevný obal oční koule a slouží k udržování tvaru oka. Je to tuhá, silná, ochranná, neprůhledná, vazivová blána bílé barvy. U dětí má namodralou barvu a ve stáří zapříčením kapének tuku nabývá lehce nažloutlé barvy. Je tvořena hustým vazivem, jež obsahuje kolagen a elastická vlákna. Na bělimu se upínají okohybné svaly. V přední části oční koule přechází v rohovku. V zadní části prostupuje bělimou zrakový nerv.

Rohovka (latinsky *cornea*) je orgán v přední části oční koule. Její tvar je podobný horizontálně uložené elipsy a zabírá přibližně 20% povrchu oční koule. Její tloušťka u dospělého člověka je přibližně 1 mm. Směrem k okraji se rohovka zplošťuje a postupně přechází v bělimu. Rohovka je průhledná, bezbarvá a elastická. Není prostoupena cévami, avšak je prostoupena nervovými vlákny a jedná se o velmi citlivý orgán. Povrch rohovky je pokryt ochranným slzným filmem. Rohovka taktéž chrání oko před vnějšími vlivy, jelikož je elas-

tická a odolná. Svým tvarem ovlivňuje samotné vidění a případné větší poškození může ovlivnit celkový zrak.

2.1.2 Střední vrstva

Střední vrstva oční koule je tvořena cévnatkou, řasnatým tělesem, duhovkou a zornicí.

Cévnatka (latinsky *choroidea*) je tenká střední vrstva oka. Je bohatě tvořena cévami, které mají za úkol vyživovat především bezcévnaté vrstvy oka. Cévnatka taktéž obsahuje hnědý pigment, zabráňující rozptyl světelných paprsků uvnitř oka a plní tak funkci tmavé komory pro sítnici. Cévnatka v přední části přechází v řasnaté těleso.

Řasnaté těleso (latinsky *corpus ciliare*) je drobný paprskovitě uspořádaný sval z hladké svaloviny ve tvaru mezikruží. Od okrajů řasnatého tělesa vybíhají tenké vlákna, na nichž je zavěšena čočka. Uvolněním nebo smrštěním svalu se mění tvar čočky, a tak se mění její světelná lomivost. Z řasnatého tělesa vystupuje duhovka.

Duhovka (latinsky *iris*) se nachází za rohovkou a je tvořena hladkou svalovinou. Má tvar mezikruží a její barva závisí na množství pigmentu uloženém v epitelové tkáni, kterým je duhovka pokryta. Barva duhovky udává typickou barvu oka.

Zornice (latinsky *pupilla*) je kruhovitý otvor uprostřed duhovky. Zornicí vstupují světelné paprsky do oka. Svalovina duhovky je seskupena takovým způsobem, že tvoří dva svaly. Kruhový sval smrštěním zornici zužuje a omezuje množství světla vstupujícího do oka. Paprskovitě orientované svalové snopce naopak zornici rozšiřují a umožňují vstup většího množství světla. Velikost zornice se reflektoricky mění podle intenzity světla, tato schopnost je nazývána jako zornicový reflex.

2.1.3 Vnitřní vrstva

Vnitřní vrstva oční koule je tvořena čočkou, sklivcem a sítnicí.

Čočka (latinsky *lens crystalina*) je zavěšena na vláknech řasnatého tělesa za duhovkou. Čočka má bikonvexní tvar a je složena z tuhé rosolovité průhledné hmoty, která umožňuje průchod světelných paprsků do nitra oka. Čočka je velice pružná a zavěšení na řasnatém tělesu umožňuje změnu poloměru zakřivení a tím ovlivňuje optickou lomivost paprsku do centra sítnice. Čočka se tedy zakřivuje na základě vzdálenosti objektu, na který se člověk v daný moment dívá.

Sklivce (latinsky *corpus vitreum*) je průhledná rosolovitá hmota, která společně s komorovou vodou vyplňuje většinu vnitřního prostoru oční koule. Udržuje tvar oka a jeho důsledkem je oko pevné a pružné. Společně s rohovkou, čočkou a komorovou vodou tvoří prostředí, kterými prochází světelné paprsky a lomí je tak, aby odraz předmětu vznikl na sítnici.


Sítnice (latinsky *retina*) je jemná a tenká vrstva tvořící vnitřní vrstvu oka, která vystýlá zadní část oční koule až k okraji duhovky. Sítnice je tvořena řadou buněčných vrstev. V sítnici jsou umístěny receptory schopné reagovat na světelné paprsky. Nejdůležitější buněčná vrstva je tvořena tyčinky a čípky, což jsou receptory pro vnímání světla a barev. Jednotlivé části sítnice popsané v této podkapitole jsou znázorněny na obrázku 2.2.

Tyčinky umožňují vnímání světla a vyskytuje se jich přibližně 120 milionů v sítnici. Čípků je pouze přibližně 6 milionů a jsou to receptory pro barevné vidění. Tyto receptory nejsou rozloženy v sítnici rovnoměrně.

V místě výstupu zrakového nervu, kde se sbíhají nervová vlákna sítnice, se nenachází žádné receptory. Pokud světelné paprsky odražené od předmětu dopadnou na toto místo, člověk předmět nevnímá. Toto místo se nazývá **slepá skvrna** a je také známo pod pojmem optický disk.

Místem nejostřejšího vidění je **žlutá skvrna** (latinsky *macula lutea*). Toto místo tvoří pouze čípky. Žlutá skvrna má v průměru přibližně 3 mm a nachází se několik milimetrů od slepé skvrny. Její střed je prohlouben. Obraz, na který se člověk dívá, se promítá právě do tohoto místa. Je nutné podotknout, že žlutá skvrna nemá ve skutečnosti žlutou barvu. Její barva je o něco málo červenější než její okolí.

Zrakový nerv a nervové buňky sítnice tvoří část centrálního nervového systému, kterou lze přímo vyšetřit. Vyšetření sítnice umožňuje odhalit a posoudit případné závažné onemocnění centrálního nervového systému, které nemusí ani mít za následek oční obtíže nebo zhoršení zraku.



Obrázek 2.2: Snímek zdravé sítnice adaptovaný z [17].

2.2 Zobrazování a snímání sítnice

Lidské oko je velice komplexní a jedinečný orgán. Způsobů vyšetření sítnice existuje velké množství. Od základních metod založených na osvětlení sítnice a jejím pozorováním očním zrcátkem. Po metody založené na měření časového rozdílu v odrazu paprsku od jednotlivých vrstev sítnice, či metody využívající ultrazvuk nebo laserový paprsek. [15]

Mnohé z těchto metod taktéž umožňují snímat sítnici. Proces, jehož produktem je získání snímku sítnice v určité formě.

Metody snímání sítnice se posledních 170 let rapidně vyvíjejí. Mezi nejčastěji používané metody v dnešní době patří optická koherentní tomografie (OCT) a používání fundus kamery pro pořizování fotografií očního pozadí. OCT se nejčastěji používá při diagnóze a léčbě pacientů s diabetickou retinopatií, makulární degenerací a zánětlivými onemocněními sítnice. OCT se také často používá při vitreoretinální chirurgii. Fotografie očního pozadí pořízené fundus kamerou se používají pro detekci diabetické retinopatie u populace. Je taktéž používána pro detekování glaukomu a věkem podmíněné makulární degenerace. [1]

Pro popsání principu fungování fundus kamery je vhodné zmínit oftalmoskop. Oftalmoskop je jednoduchý a základní přístroj při vyšetřování sítnice. [15]

2.2.1 Oftalmoskopie

Oftalmoskopie je vyšetření očního pozadí oftalmoskopem. Subjektem vyšetření je sklivec, zrakový nerv a především sítnice. Principem oftalmoskopie je osvětlení nitra oka adekvátně intenzivním světlem a následným pozorováním paprsků odražených od sítnice. Avšak osa pozorování musí být velmi blízká ose osvětlení k docílení tzv. červeného reflexu. Oftalmoskopii dělíme na přímou oftalmoskopii a nepřímou oftalmoskopii. [15]

Přímá oftalmoskopie využívá přímý oftalmoskop umožňující jednoduché vyšetření z krátké vzdálenosti. Zdroj světelných paprsků je umístěn pod okénkem, jehož účelem je pozorování sítnice. Obraz určité oblasti sítnice je pozorován jedním okem. Vyšetření jiných oblastí sítnice lze dosáhnout změnou sklonu přístroje, případně taktéž změnou pohledového směru vyšetřovaného oka. Přímá oftalmoskopie umožňuje jednoduché detailní vyšetření, avšak méně přehledné. Taktéž neumožňuje prostorový vjem, jelikož obraz sítnice se pozoruje jedním okem. Přístroj může být vylepšen použitím různých světelných filtrů nebo použitím různých průměrů světelného kotouče. Viditelná část očního pozadí záleží na průměru zornice a vyšetřujícího a vyšetřovaného a za normálních okolností činí přibližně $5-8^\circ$. [15, 42]

Nepřímá oftalmoskopie využívá nepřímý oftalmoskop umožňující vyšetření sítnice z větší vzdálenosti než u přímého oftalmoskopu. Využívá vyšetřovací čočku, kterou vyšetřující drží před okem vyšetřovaného v odpovídající vzdálenosti. Přes tuto čočku pozoruje obraz sítnice. Obraz sítnice se zobrazuje přes čočku jako reálný a převrácený. Obraz sítnice je méně zvětšený než při vyšetření přímým oftalmoskopem, ale čočka umožňuje zobrazení větší oblasti sítnice a vyšetření je přehlednější. Jelikož obraz sítnice pozoruje vyšetřující oběma očima, nepřímý oftalmoskop umožňuje prostorový vjem. Vyšetřující má zorné pole přibližně 45° , což je mnohem větší oblast než u přímé oftalmoskopie. Zvětšení a viditelnou oblast očního pozadí lze měnit dle výběru použité čočky. [15, 28, 42]

2.2.2 Fundus kamera

Na podobném zobrazovacím principu, na kterém je založena nepřímá oftalmoskopie, jsou založeny přístroje, nazývané fundus kamery, umožňující záznam obrazu očního pozadí na klasické fotografie nebo ve formě digitálního obrazu [15]. Snímání očního pozadí je proces, jehož produktem je dvoudimenzionální reprezentace trojdimenzionálních semi-transparentních vrstev očního pozadí, které jsou získané pomocí odražení světelných paprsků. Tato podkapitola je převážně převzata ze [1], jestliže není zmíněno jinak.

Technik snímání očního pozadí existuje velké množství. Mezi důležité zmínky patří:

1. Focení očního pozadí - snímek znázorňuje množství odražených paprsků světla určité vlnové délky.
2. Barevné focení očního pozadí - snímek znázorňuje množství odražených paprsků vlnových délek červené, zelené a modré barvy.
3. Stereo focení očního pozadí - snímek znázorňuje množství odražených paprsků světla ze dvou a více úhlů pro získání rozlišení hloubky.
4. Hyperspektrální snímání - snímek znázorňuje množství odražených paprsků světla z několika specifických pásem vlnových délek.
5. Skenovací laserová oftalmoskopie (SLO) - snímek znázorňuje množství odraženého laserového světla o jedné vlnové délce získaného v časové sekvenci.
6. Adaptivní optika SLO - snímek znázorňuje množství odraženého laserového světla opticky korigovaného modelováním aberací v čele jeho vlny.
7. Fluoresceinová angiografie a indocyaninová angiografie - snímek znázorňuje množství emitovaných fotonů z fluoresceinového nebo indocyaninového zeleného fluoroforu, který byl podán do cévního oběhu pacienta.

Snímání očního pozadí těmito metodami představuje i mnoho technologických výzev. Sítnici je nutné osvětlit externě a světelné paprsky musí přejít zornicí, jejíž průměr je pouhých 2–8 milimetrů. Tato záležitost byla vždy primárním problémem ve snímání sítnice. Snímání očního pozadí fundus kamerou je technicky náročné a historicky zahrnovalo drahé vybavení vyžadující kvalifikované operátory.

Avšak začátkem 21. století bylo vynaloženo velké úsilí na dostupnějším zpřístupnění snímání očního pozadí v důsledku následujících tří nejdůležitějších změn:

1. Přejít od filmových k digitálním snímkům a v důsledku toho vzrostla důležitost systémů pro archivaci obrázků a komunikačních systémů v klinické oftalmologii, což také umožňuje integraci s elektronickými zdravotními záznamy.
2. Byl vytvořen požadavek na včasnou detekci onemocnění sítnice u populace pomocí snímání očního pozadí.
3. Jednodušší ovládání fundus kamer neoftalmickými fotografy, digitálnímu zobrazování s infračerveným zaostřováním a zvyšující se reprodukovatelnost prostřednictvím standardizovaných zobrazovacích protokolů.



Obrázek 2.3: Digitální fundus kamera [15].

2.2.3 Optická koherentní tomografie

Optická koherentní tomografie (OCT) je technika, která umožňuje snímat dvourozměrný optický řez sítnicí. Tato metoda je založena na nízkokoherentní interferometrii. Tato metoda je založena na měření časového rozdílu v odrazu paprsku od jednotlivých vrstev sítnice a referenčního paprsku odraženého od pomocného zrcátka. Jednotlivé vrstvy sítnice mají rozdílnou schopnost odrážet světlo (reflektivitu), podle intenzity odraženého světla lze tedy jednotlivé sítnicové vrstvy rozlišit. Reflektivita jednotlivých tkání je ve výsledku zobrazena v domluvené škále barev. Jedinečná hloubková rozlišovací schopnost přístroje je umožněna použitím světelného zdroje s možností nízké délky koherence. Paprsky použitého infračerveného světla mohou pronikat hluboko do živých tkání. [15, 52]

Nejmodernější přístroje umožňují rozeznání jednotlivých vrstev na téměř buněčné úrovni rozlišení. Kombinací principu OCT a konfokálního laserového skenování je možné získat trojrozměrný obraz s až 10x vyšší hloubkovou rozlišovací schopností než u běžného konfokálního skenovacího laseru. [15]



Obrázek 2.4: Vyšetření na optickém koherentním tomografu [53].

2.3 Onemocnění sítnice

Detekované patologie mikroaneuryzmata a exsudáty patří mezi dřívější příznaky diabetické retinopatie. Jejich přesným automatizovaným detekováním je možné pomoci specialistům při jejich detekování nebo je možné potenciálně nahradit specialisty v chudších částech světa, jelikož vzdělávat oční specialisty je časově a finančně náročné. Tato podkapitola se zabývá popisem jednotlivých patologií.

2.3.1 Mikroaneuryzmata


Mikroaneuryzmata jsou dilatace sítnicových kapilár kuličkového, hroznovitého nebo větevitého tvaru na optickém mikroskopu [42, 47]. Tvar mikroaneuryzmat připomíná menší vakovité výstupky či výchlípky ve stěnách sítnicových kapilár [18, 42]. Různé tvary mikroaneuryzmat, které se mohou vyskytovat, jsou zobrazeny na obrázku 2.5. Oftalmoskopicky se mikroaneuryzmata jeví jako červené tečky o průměru 10–100 mikrometrů [18, 42]. Jejich výskyt na barevném obrázku sítnice pořízeným fundus kamerou lze vidět na obrázku 2.6. Mikroaneuryzmata mohou být hypercelulární nebo acelulární. Hypercelulární mikroaneuryzmata nejspíš vznikají proliferací endotelií (buňky vystylající cévy [51]) [42, 47].

Jedním z nejranějších příznaků diabetické retinopatie je ztráta pericytů, avšak tento jev je možné zjistit pouze histologicky. Většinou nejranějším klinicky viditelným příznakem diabetické retinopatie jsou právě mikroaneuryzmata. [12, 18, 42]

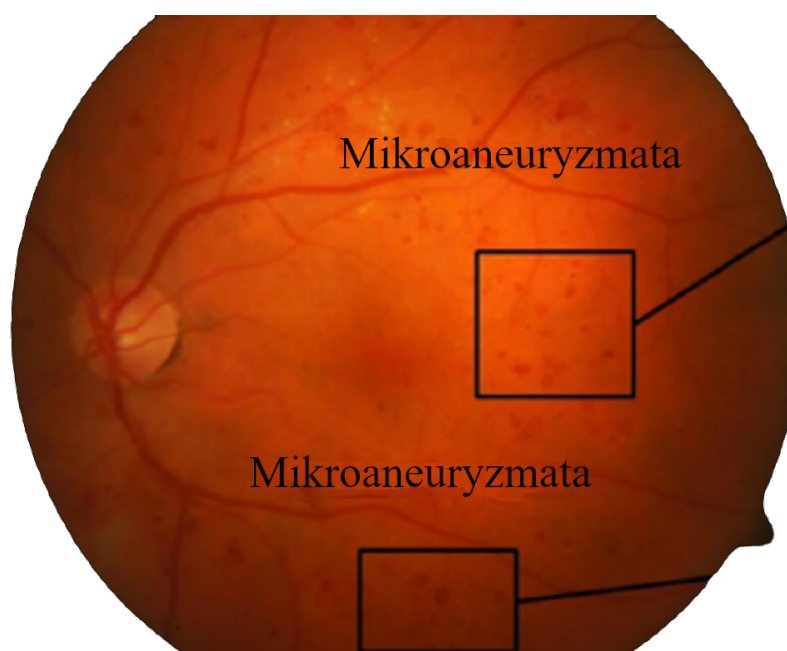
Mikroaneuryzmata jsou nejčastěji nalezeny u diabetické retinopatie, ale můžeme je pozorovat i u jiných cévních onemocnění [18, 42]. Mikroaneuryzmata pravděpodobně vznikají následkem ztráty pericytů [42].

Taktéž byla potvrzena korelace mezi počtem mikroaneuryzmat a závažností a pravděpodobnou progresí diabetické retinopatie, alespoň pro časná stádia onemocnění [22].

Mikroaneuryzmata mohou zanikat a opět se objevovat a sama nepředstavují závažnou patologii, avšak jejich narůstající počet bývá doprovázen dalšími mikrovaskulárními změnami [42].



Obrázek 2.5: Klasifikace tvarů mikroaneuryzmat adaptovaná z [6].



Obrázek 2.6: Mikroaneuryzmata na snímku sítnice adaptovaném z [2].

Vznik mikroaneuryzmat

Zdá se, že pericyty (perivaskulární vřetenovité buňky obklopující kapiláry [51]) vykazují antiproliferativní účinek a ztráta pericytů může vysvětlovat vývoj hypercelulárních mikroaneuryzmat. Acelulární mikroaneuryzmata nejspíš vznikají z hypercelulárních mikroaneuryzmat, které se stanou acelulární kvůli buněčné smrti endotelií a pericytů. [31]

Ztráta pericytů může také vést k oslabení kapilární stěny, což podporuje rozvoj mikroaneuryzmat na strukturálně slabých místech. Pericyty mohou působit jako buňky hladkého svalstva větších cév, vyvíjející tonus na cévní stěnu, aby působily proti transmurálnímu tlaku. Ztráta tonusu pericytu může vést k fokální dilataci cévní stěny vedoucí k rozvoji mikroaneuryzmatu. Transmurální tlak kapilárního řečiště je však vzhledem k arteriální cirkulaci nízký a retinální kapilární mikroaneuryzmata se mohou vyvinout u jiných onemocnění, u kterých není pozorována ztráta pericytů. [3, 7, 47]

Mikroaneuryzmata na snímcích sítnice

Vzhledem k tomu, že retinální kapiláry jsou příliš malé na to, aby je bylo možné snímat pomocí normálního focení očního pozadí, jsou mikroaneuryzmata klasicky popisována jako zřetelně malé objekty. Pomocí barevného focení očního pozadí se jeví jako červené a na snímcích bez červeného kanálu se zdají tmavé barvy. V praxi se vzhled mikroaneuryzmat může poněkud odchylovat od klasického popisu. Mohou se objevit ve spojení s většími cévami nebo jako konglomerace více než jednoho mikroaneuryzmatu. Mikroaneuryzmata jsou lépe vizualizována fluoresceinovou angiografií s více viditelnými mikroaneuryzmaty než na barevných snímcích očního pozadí. Nicméně i další rysy, jako jsou defekty retinálního pigmentového epitelu, se mohou jevit jako mikroaneuryzmata a při identifikaci jednotlivých mikroaneuryzmat je zapotřebí určité opatrnosti. [18]

Odlíšení mikroaneuryzmat a tečkovitých hemoragií

Mikroaneuryzmata může být těžké odlišit od tečkovitých hemoragií, avšak při fluoresceinové angiografii mikroaneuryzmata zřetelně září [18, 42, 47], zatímco hemoragie fluorescenci blokují [42]. Vzhledem k tomu, že klinické důsledky přítomnosti tečkovitých hemoragií a mikroaneuryzmat jsou dostatečně podobné, není obvykle nutné, aby automatizovaný detektor mikroaneuryzmat mezi nimi rozlišoval [18].

Automatizovaná detekce mikroaneuryzmat na barevných snímcích sítnice

Vzhledem k tomu, že mikroaneuryzmata lze poměrně snadno popsat, jsou dobře vizualizovatelným cílem a jejich počet má jednoznačné klinické důsledky, byla jednou z prvních lézí vybraných pro automatizovanou analýzu obrazu. Časně pokusy se zaměřily na detekci mikroaneuryzmat ve fluoresceinových angiografických snímcích, kde jsou lépe vizualizovatelné. Vzhledem k tomu, že fluoresceinová angiografie představuje nepřijatelné zdravotní riziko pro vyšetření očí a technologie barevných digitálních fotoaparátů dostatečně pokročila, existuje nyní krok k provádění automatizované detekce mikroaneuryzmat na barevných snímcích očního pozadí jako doplněk k automatizovanému vyšetření očí. [18]

2.3.2 Tvrdé exsudáty

Tvrdé exsudáty patří k lézím způsobeným diabetickou retinopatií a jsou jednou z nejčastěji se vyskytujících lézí. Tvrdé exsudáty jsou typicky viditelné při oftalmoskopii jako ostře ohraničená žluto-bílá ložiska různých velikostí a tvarů. Tvrdé exsudáty lze vidět jako jednotlivé skvrny, shluky, nebo se nacházejí ve velkých prstencích kolem prosakujících kapilár. Mají také tendenci se tvořit v zadní části oční koule ve spojení se žlutou skvrnou. Tvrdé exsudáty představují únik z okolních kapilár a mikroaneuryzmat v sítnici. Velikost a distribuce exsudátů se může během progresu onemocnění lišit. Tvrdé exsudáty se mohou objevovat a mizet v průběhu měsíců nebo let, avšak obvykle mají tendenci zvětšovat svůj objem v neléčené sítnici. Pokud tvrdý exsudát zasahuje do oblasti žluté skvrny, tak vidění jedince může být vážně ohroženo. [18, 47]

Tvrdé exsudáty na snímcích sítnice

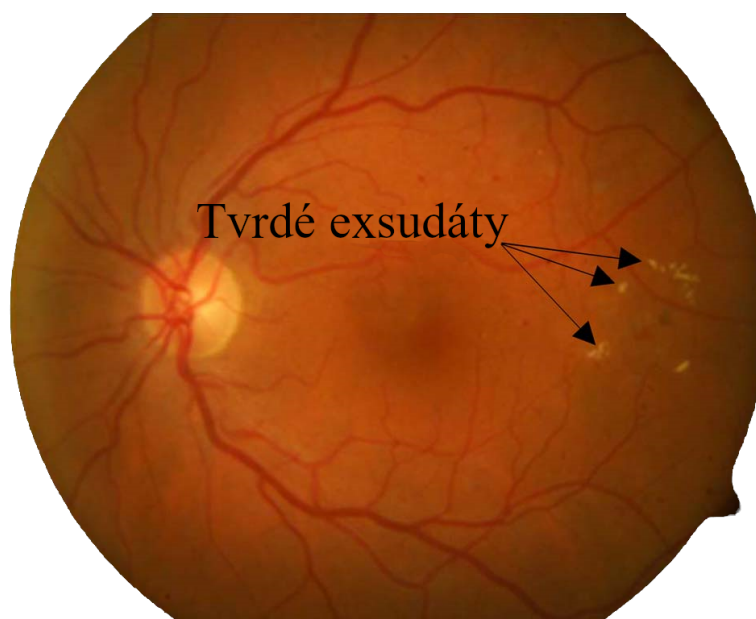
Na snímcích pořízených pomocí OCT jsou tvrdé exsudáty viditelné jako hyperreflexní ložiska v sítnici. Na snímcích pořízených fluoresceinovou angiografií tvrdé exsudáty blokují fluorescenci. [47]

Automatizovaná detekce tvrdých exsudátů

Existuje mnoho příčin pro získávání falešných pozitiv během detekce tvrdých exsudátů. Tvrdé exsudáty je možné algoritmem zaměnit s jasnými optickými artefakty způsobenými například prachem a jiným materiálem na přední čočce fundus kamery nebo odrazy od vnitřní omezující membrány. [18]

Tvrdé exsudáty je taktéž snadné zaměnit s drúzami, které se objevují u žluté skvrny a které je možné pozorovat u makulární degenerace [18]. Při stereoskopickém snímání sítnice jsou tvrdé exsudáty snadněji rozeznatelné od drúz, které sídlí vně sítnice [47].

Dle názoru [18] je nadměrná diagnostika tvrdých exsudátů s pravděpodobnějším výskytem falešných pozitiv menší problém, než potenciální tvrdý exsudát nedetekovat. Ale připouští, že názor oftalmologů se může lišit, dle jejich pracovní vytíženosti.



Obrázek 2.7: Tvrdé exsudáty na snímku sítnice adaptovaném z [19].

2.3.3 Měkké exsudáty

Měkké exsudáty, taktéž známé jako vatovité ložiska, jsou malé kypré žlutobělavé nebo šedé léze a jejich tvar může být kulatý nebo oválný. Vzhled měkkého exsudátu připomíná malý mrak nebo vatu. Vyskytují se v povrchové vrstvě sítnice. Tyto léze se nazývají měkké exsudáty, avšak v moderní literatuře se častěji vyskytují pod názvem vatovité ložiska pro jejich charakteristický vzhled. Měkké exsudáty mohou být ohraničeny mikroaneurysmaty a nebo se mohou vyskytovat poblíž hemoragií. [18, 42, 47]

Vznik měkkých exsudátů

Tyto exsudáty vznikají v důsledku nedostatku prokrvenosti (ischemie) sítnice vzniknuté obstrukcí retinální arterioly. Vzniknutý fokální nedostatek kyslíku vede k blokáde axoplazmatického toku ve vrstvě nervových vláken. Tato blokáda má za následek ukládání intra-axonálních organel vedoucích ke tvorbě ložisek ve tvaru vat. [18, 30, 42, 47]

Následky nalezení měkkých exsudátů

Měkké exsudáty výjimečně způsobují zrakové potíže a zpravidla se během 5–7 týdnů ztrácejí. Nejčastěji se nacházejí u diabetické retinopatie a systémové hypertenze, avšak se mohou vyskytovat i u jiných onemocnění. Nalezení měkkých exsudátů u pacienta je známkou závažného onemocnění a je nutné pacienta podrobně vyšetřit. Nalezení i pouhého jednoho měkkého exsudátu na jinak zdravé sítnici vyžaduje důkladné vyšetření. [42, 47]

Detekce měkkých exsudátů

Svým tvarem a vzhledem jsou měkké exsudáty, tvrdé exsudáty a drůzy velmi podobné a je tak nutné implementovat automatizovaný detektor, který dokáže s adekvátní přesností rozlišovat mezi těmito lézemi. Detekce měkkých exsudátů vyžaduje věrný záznam údajů o jasnosti, aby bylo možné identifikovat léze charakterizované difúzními okraji a lokálním zvýšením jasnosti. Málo zjevné léze pozorované na vysoce kvalitních barevných snímcích sítnice mohou indikovat místní oblasti ischemie, které jsou jednoduše znatelné pomocí fluoresceinové angiografie. [18, 47]



Obrázek 2.8: Měkké exsudáty, tvrdé exsudáty a mikroaneuryzmata na snímku sítnice adaptovaném z [25].

Kapitola 3

Metody detekce patologií na snímcích sítnice

Metody detekce patologií na snímcích sítnice se neustále vyvíjejí. Tato kapitola má za cílem shrnout různé způsoby detekce, které již byly vyzkoušeny v praxi. Podkapitola 3.1 popisuje nejčastěji používané metody předzpracování snímků. Podkapitola 3.2 a 3.3 popisují různé přístupy k detekci vybraných patologií.

3.1 Metody předzpracování snímků sítnice

Pro dosažení vyšší přesnosti při detekování různých objektů na snímcích sítnice se snímky sítnice mohou předzpracovat. Různé metody předzpracování mají různé následky. Předpracováním je možné zvýšit celkovou kvalitu snímku, odebrat nedůležité informace ze snímku a tím taktéž i urychlit samotný algoritmus detekování, či například zvýraznit určité útvary. Tato podkapitola se zabývá častými metodami předzpracování snímků sítnice, které se používají v praxi.

Odstranění černého pozadí

Odstraněním černého pozadí snímku sítnice je možné zmenšit celkovou velikost snímku a odstranit potenciálně zavádějící rysy v neinformativních oblastech černého pozadí. Avšak automatizované odstranění černého pozadí může být lehce komplikovanější pro snímky sítnice, kde se sítnice nenachází ve tvaru kruhu. Taktéž je možné ztratit při odstraňování potenciální data na hranici mezi sítnicí a pozadím. [29]

Ořezávání a změna velikosti snímku

Jelikož snímky sítnice se vyskytují v různých rozlišeních, je možné standardizovat velikost snímků na jednu určitou hodnotu škálováním a případným přidáním segmentů černého pozadí pro snímky sítnice, kde se sítnice vyskytuje ořezaná bez horní a spodní části. [50]

Použití pouze zeleného kanálu barevného snímku

Barevný snímek sítnice je tvořen třemi barevnými kanály (červený, modrý a zelený). Největší rozdíl v kontrastu mezi mikroaneuryzmaty, exsudáty, cévy a pozadím sítnice lze pozorovat na zeleném kanálu. Je tedy velmi obvyklé méně informativní kanály odstranit a zanechat

pouze zelený kanál. Tímto procesem se taktéž zmenší celková velikost snímku. Avšak je nutné opomenout, že odstraněním méně informativních kanálů může vést k horším výsledkům detekci při použití metod detekce založených na hlubokém učení. [29, 50]

Vylepšení kontrastu

Vylepšením kontrastu snímku je možné zvýraznit určité útvary pro jejich přesnější detekování. Metod zlepšení kontrastu existuje velké množství. Mezi jedny z nejčastěji používaných metod patří následující metody.

1. Kontrastně limitovaná adaptivní ekvalizace histogramu (CLAHE) patří mezi nejčastěji používanou metodu, jelikož snímky sítnice bývají většinou nerovnoměrně osvětleny (jas se snižuje s rostoucí vzdáleností od středu sítnice). CLAHE rozděluje vybraný kanál do kontextových oblastí a následně aplikuje na každou oblast ekvalizaci histogramu. Tento proces vyrovnává rozložení jasu napříč celým snímkem, avšak samotný proces zpracovává menší regiony v určité momenty než-li celý snímek najednou. Tento proces může vytvořit artefakty, jestliže snímek obsahuje rovnoměrně distribuovaný šum. [29, 56, 38]
2. Ekvalizace histogramu pro vylepšení kontrastu může být provedeno i základní ekvalizací histogramu, avšak výsledek může být menší kvality než při provedení ekvalizace pomocí metody CLAHE. [38]
3. Morfologické operace je taktéž možné použít pro zlepšení kontrastu. Často používaná taková operace je například bottom-hat transformace, která získává rozdíl mezi uzávěrem původního snímku a původním snímkem. [38]

Odstranění šumu

1. Mediánové filtrování je efektivní metoda pro řešení izolovaného šumu bez rozmazání ostrých hran. Mění pixely o medián všech pixelů v okolí malého posuvného okna. Mediánový filtr je vynikající volbou pro eliminaci šumu a artefaktů získaných horizontálním skenováním. Pro současné snížení šumu a zachování okrajů v obrázcích barevného pozadí je mediánové filtrování účinnější než případná konvoluce. [38, 56]
2. Wienerovo filtrování je lineární odhad původního snímku. V našem případě je původní snímek zeleným kanálem barevného snímku pozadí. Wienerův filtr optimálním způsobem minimalizuje střední kvadratickou chybu. Filtr také zachovává okraje a další frekvenční složky anatomické struktury. [38]
3. Subtrakce Gaussova rozostření je jedna z dalších často používaných metod. Rozostření zmenšuje šum a subtrakcí rozmazaných snímků se obraz zaostří. Ve výsledném snímku jsou především zachovány vysokofrekvenční složky, které byly zrušeny Gaussovým filtrem. Tímto procesem je taktéž sníženo nerovnoměrné osvětlení. Avšak ladění parametrů tohoto filtru na větším počtu snímků je časově náročná práce. Při použití u homogenních snímků zachycených jednou fundus kamerou může tato metoda zlepšit výkonnost závěrečného algoritmu v detekování. Ale taktéž může přidat různé artefakty, jestliže snímky sítnice obsahují rovnoměrně rozložený šum. [29]

Odstranění cév

Odstraněním cév na snímku sítnice se může drasticky zredukovat počet falešně pozitivních nálezů mikroaneuryzmat, jelikož místa, kde se právě překrývají cévy, připomínají mikroaneuryzmata. Avšak tato metoda je složitější na implementaci a může vést ke ztrátě mikroaneuryzmat, která se vyskytují poblíž cév. [29]

Odstranění optického disku

Odstraněním optického disku je možné zlepšit detekci mikroaneuryzmat a exsudátů. Odstranění snižuje počet falešných pozitiv mikroaneuryzmat na optickém disku. A jelikož optický disk má podobné charakteristiky tvrdých exsudátů, tak také snižuje počet falešných pozitiv exsudátů. Tento proces může však odstranit mikroaneuryzmata, které se vyskytují poblíž optického disku a jedná se o složitější implementaci. [29, 56, 18]

3.2 Metody detekce mikroaneuryzmat

Metody detekce mikroaneuryzmat na snímcích sítnic lze kategorizovat do tří hlavních kategorií. Mezi tyto kategorie patří digitální zpracování obrazu, strojové učení a hluboké učení. Metody popsané digitálním zpracováním obrazu obsahují především použití filtračních a prahových metod. Metody založené na strojovém učení používají metody bez učitele nebo metody s učitelem. Algoritmy založené na hlubokém učení se snaží naučit charakteristiky mikroaneuryzmat pro jejich následnou detekci z datové sady snímků sítnice. Tato podkapitola je převzata z práce [29], která zanalyzovala a zhodnotila přes 60 vědeckých článků zabývajících se detekcí mikroaneuryzmat na snímcích sítnice.

Digitální zpracování obrazu

Digitální zpracování obrazu je založeno na předzpracování snímku, následným filtrováním snímku a závěrečným vyznačením mikroaneuryzmat s použitím prahování pro minimalizaci falešně pozitivních nálezů.

Mezi nejčastěji používané metody předzpracování patří použití CLAHE algoritmu na zeleném kanálu snímku sítnice. Následně bývá použit nelineární mediánový filtr pro odstranění šumu na snímku. Morfologické operace související s tvarem mikroaneuryzmat taktéž bývají použity na zeleném kanále snímku pro odstranění šumu a zanechání potřebných útvarů. Odstranění cév patří mezi časté metody předzpracování taktéž. A jelikož velikost snímků se v praxi liší, tak se většinou snímky škálují na pevně danou velikost.

K transformaci vstupního snímku do požadovaného formátu se používá filtrování. Filtry se aplikují k potlačení vysokých nebo nízkých frekvencí, aby se zlepšila kvalita snímku, ale taktéž se mohou použít k extrakci potenciálních mikroaneuryzmat. Pro zvýraznění mikroaneuryzmat bývají používány kruhové Gaussovy filtry, jelikož tvar mikroaneuryzmat je většinou podobný kruhovitému tvaru, a morfologické operace.

Předzpracovaný snímek je konvulován s Gaussovou maskou za cílem zachycení tvarů mikroaneuryzmat. Taktéž tzv. matched filtr společně s kruhovými dvoudimenzionálními Gaussovými maticemi se používá pro zvýraznění mikroaneuryzmat. Kruhová Houghova transformace je taktéž často používaná technika k extrakci rysů mikroaneuryzmat. Tato technika dokáže detekovat kruhy v nedokonalých snímcích sítnice.

Závěrečná fáze je prahování za cílem minimalizace počtu falešně pozitivních nálezů mikroaneuryzmat na snímku sítnice. Obvykle se používají odchylky v globálních prahových

hodnotách a jestliže nejsou anotované testovací masky k dispozici, použije se pevná prahová hodnota pro generování masek mikroaneuryzmat z filtrovaných snímků.

Strojové učení

Detekce pomocí strojového učení je převážně složena z předzpracování snímku, extrakcí rysů a klasifikací. Segmenty snímků o pevné velikosti nebo potenciální kandidátní segmenty se používají ke generaci rysů. Většina těchto segmentů nemusí obsahovat mikroaneuryzmata. Kandidátní segmenty mohou být taktéž generovány pomocí různých technik zpracování obrazu za cílem snížení výpočetního času.

Mezi časté metody předzpracování patří zejména vylepšení kontrastu pomocí algoritmu CLAHE na zeleném kanále snímku sítnice. Normalizace zeleného kanálu snímku patří mezi časté techniky. Určité práce vytváří segmenty snímku bez dalšího předzpracování, avšak většina prací experimentuje s dalšími technikami za cílem generování segmentů snímku, na kterých se mohou vyskytovat mikroaneuryzmata. Odstranění cév a prahování patří mezi populární metody předzpracování

Různé rysy jsou extrahovány z obdržených segmentů. Mezi tyto rysy může například patřit tvar, textura a statistické rysy intenzity barvy. Například tvar lze popsat elipticitou, plochou a průměrem. Tyto rysy jsou následně extrahovány z kandidátních segmentů. Velikost rysů je následně zmenšena redukcí dimenzí a to metodami jako například analýza hlavních komponent (PCA) nebo singulárním rozkladem (SVD).

Klasifikátor je trénován získanými rysy z kandidátních segmentů. Algoritmy strojového učení s učitelem jsou široce používány, které používají anotované masky obsahující podrobnosti o případné přítomnosti mikroaneuryzmat. Mezi časté klasifikátory patří metoda podpurných vektorů (SVM), adaptivní posilování (AdaBoost), algoritmus k-nejbližších sousedů, či umělá neuronová síť (ANN). Velký rozdíl mezi počtem regionů, kde se nachází a nenachází mikroaneuryzmata, způsobuje nevyváženost tříd. Pro vyřešení tohoto problému byl zjištěn úspěch s klasifikátory RUSBoost, které se tak staly populární při řešení tohoto problému.

Hluboké učení

V poslední době architektury neuronových sítí ukazují slibné výsledky při automatizované detekci mikroaneuryzmat. Velká výhoda využití hlubokého učení k detekci mikroaneuryzmat je možnost minimalizování fáze předzpracování a eliminace fáze extrakce rysů. Metody založené na hlubokém učení jsou tvořeny dvěma hlavními fázemi. Mezi tyto fáze patří předzpracování snímků a trénování neuronové sítě.

Mezi časté metody předzpracování snímku patří vylepšení kontrastu algoritmem CLAHE na zeleném kanále snímku. Často se používají segmenty snímku sítnice o pevné délce, avšak některé práce experimentují s pevnou velikostí celého snímku pro trénování neuronové sítě.

Pro detekci mikroaneuryzmat se široce používají konvoluční neuronové sítě (CNN) s rektifikovanými lineárními aktivační funkcí (ReLU). K trénování sítě se použijí předzpracované snímky nebo segmenty očního pozadí. Parametry neuronové sítě jsou určeny heuristicky na základě rozsáhlých experimentů. Pro včasnou diagnostiku diabetické retinopatie se také experimentuje s předem vyučenou reziduální sítí (ResNet) s mapami pozornosti. Taktéž bývají používány sítě U-Net, u kterých se maska mikroaneuryzmat na snímku nebo segmentu generuje pro daný předzpracovaný snímek nebo segment očního pozadí pomocí vrstev konvolucí a dekonvolucí.

3.3 Metody detekce exsudátů

Tato podkapitola se zabývá analýzou metod detekcí exsudátů používaných v praxi. Jelikož automatizované detektory exsudátů obvykle obsahují detekci tvrdých a měkkých exsudátů [18], tak lze tyto metody s určitou přesností použít pro detekci obou typů exsudátů. Metody detekce exsudátů lze rozdělit do tří hlavních kategorií a to digitálního zpracování, strojového učení a hlubokého učení. Tato podkapitola je převážně převzata z vědeckých článků [19, 56] pro analýzu prací digitálního zpracování a strojového učení, které se zabývaly shrnutím informací zabývajících se detekcí exsudátů většího počtu vědeckých prací.

Předzpracování

Obvyklé metody předzpracování jsou obdobné metodám popsaných v kapitole 3.1. Tedy metody za cílem zlepšení kontrastu, odstranění šumu a ekvalizace histogramu. Je nutné opomenout důležitost odstranění optického disku pro jeho podobný vzhled k tvrdému exsudátu. Přestože určité práce používají extrakci zeleného kanálu, mnohem častější je konverze barevného prostoru RGB do prostoru HSI nebo LUV kvůli charakteristickým barvám exsudátů.

Digitální zpracování

Mezi metody digitálního zpracování převážně patří růst regionů, prahování a morfologické operace. Růst regionů (anglicky region growing) ukazuje slibné výsledky u exsudátů s definovanou hranicí a to nejlépe u jasně viditelných tvrdých exsudátů. Použití globálního a lokálního prahování nebo prahování pomocí histogramu je taktéž rozumnou alternativou.

Morfologické operace lze použít pro automatizovanou detekci exsudátů a dalších jasných regionů na barevných snímcích sítnice jako je například optický disk. Samotné morfologické operace se často používají v kombinaci s dalšími metodami pro přesnější závěrečnou detekci. Fuzzy c-means shlukování společně s morfologickými operacemi patří mezi oblíbené kombinace.

Strojové učení

Mezi nejčastější používanou metodu detekce exsudátů patří fuzzy c-means shlukování. Mnoho prací převážně zkoušejí rozdílné metody předzpracování nebo použití tohoto shlukování společně s další metodou nebo metodami. Ale je nutné opomenout i použití k-means shlukování. Samotné fuzzy c-means shlukování bylo vyzkoušeno v kombinaci s neuronovými sítěmi převážně pro závěrečnou klasifikaci objektů. Další často používanou metodou ve strojovém učení patří SVM s výběrem charakteristik exsudátů.

Hluboké učení

Metody hlubokého učení se staly velmi populárními až v posledních letech. Pro detekci exsudátů se používají různé konvoluční neuronové sítě (CNN), které mohou být předem vyučené, jako například ResNet, Inception nebo VGG pro klasifikaci. Parametry neuronové sítě jsou určeny heuristicky na základě rozsáhlých experimentů. Metody použité v hlubokém učení jsou obdobné metodám popsaným v podkapitole 3.2 detekce mikroaneuryzmat pomocí hlubokého učení. [54]

Kapitola 4

Datové sady snímků sítnic

Datové sady snímků jsou důležité pro závěrečné testování automatizovaného detektoru objektů. Při testování na větším počtu snímků je možné získat objektivnější výsledky metrik detekování. Větší množství snímků taktéž umožňuje potenciálně trénovat modely na základě hlubokého učení pro následné detekování objektů.

Jeden z problémů detekování patologií na snímcích sítnice je obdržení většího počtu snímků sítnic, které obsahují patřičné patologie, jelikož se jedná o velmi specifické snímky. V případě trénování neuronové sítě je nutné vlastnit anotované snímky sítnic obsahující informace o lokalitě patologií. Tvorba těchto anotací je časově náročná a je nutné, aby byla provedena specialisty. Tato skutečnost vede k menšímu počtu veřejně dostupných anotovaných snímků sítnic.

Při řešení této diplomové práce bylo bráno v potaz obdržení většího počtu anotovaných barevných snímků sítnic. Barevné snímky sítnic jsou více rozšířené a více veřejně dostupné než například snímky pořízené optickou koherentní tomografií (OCT). Tato kapitola popisuje použité datové sady v této práci.

DiaRetDB1 V2.1

Datová sada DiaRetDB1 V2.1 [21] obsahuje 89 barevných snímků sítnic. Z těchto snímků 84 obsahuje příznaky diabetické retinopatie a 5 snímků jsou zdravých sítnic. Anotace obsahují informace týkající se lokalit patologií na snímcích. Mezi tyto patologie patří mikroaneuryzmata, tvrdé exsudáty, měkké exsudáty a hemoragie. Ke každému snímku jsou přiřazeny až čtyři soubory obsahující anotace. Toto spočívá z důvodu, že anotace byly vytvořeny nezávisle čtyřmi lékařskými specialisty. Barevné snímky sítnice byly uloženy do formátu PNG s rozlišením 1500 x 1152 pixelů a každý snímek má přidělen až čtyři soubory obsahující anotace ve formátu XML. Snímky byly pořízeny fundus kamerou s pokrytím sítnice 50°. Verze 2.1 této datové sady byla vybrána z důvodu, že obsahuje anotace právě ve formátu XML, které lze snadněji zpracovat než masky ve formátu grafického souboru, které jsou k dispozici v datové sadě DIARETDB1 [20].

e-ophta

Datová sada e-ophta [4] je rozdělena na dvě datové sady. První datová sada se nazývá e-ophta EX a obsahuje 47 snímků sítnic obsahující tvrdé exsudáty a 35 snímků zdravých sítnic. Druhá datová sada se nazývá e-ophta MA a obsahuje 148 snímků sítnic obsahující mikroaneuryzmata a 233 snímků zdravých sítnic. Barevné snímky sítnice byly uloženy do

JPG formátu s různým rozlišením. Tyto datové sady obsahují binární masky ve formátu PNG označující umístění patologií.

OIA-DDR

Datová sada OIA-DDR [24] obsahuje 13 673 barevných snímků sítnic. Datová sada obsahuje tři kategorie anotací. První kategorie popisuje úroveň diabetické retinopatie snímků. Další dvě kategorie obsahují informace nápomocné k detekci a segmentaci patologií na snímcích sítnice, avšak tyto anotace jsou k dispozici pouze k vybraným 757 snímkům. Mezi vybrané anotované patologie patří mikroaneuryzmata, tvrdé exsudáty, měkké exsudáty a hemoragie. Při pořizování snímků bylo použito 42 fundus kamer s pokrytím sítnice 45° a to zejména Topcon D7000, Topcon TRC NW48, Nikon D5200 a Canon CR 2. Barevné snímky sítnice byly uloženy do formátu JPG s různým rozlišením a každý snímek má přidělený právě jeden soubor obsahující anotace ve formátu XML.

FNUSA

Tato datová sada byla obdržena od Fakultní nemocnice u sv. Anny v Brně a obsahuje 120 barevných snímků sítnic. Oficiální informace k této datové sadě nebyly obdrženy s touto sadou, a tak nejsou k dispozici. Jelikož se nejedná o veřejně dostupnou datovou sadu, bude se nadále v textu tato sada označovat pod jménem FNUSA dle začínajících písmen této nemocnice. Samotná datová sada obsahuje anotace ke snímkům sítnice obsahující informace lokalit objektů na snímcích. Mezi tyto objekty například patří mikroaneuryzmata, tvrdé exsudáty, měkké exsudáty, hemoragie nebo optický disk. Barevné snímky sítnice byly uloženy ve formátu JPG s různým rozlišením a každý snímek má přidělený právě jeden soubor obsahující anotace ve formátu JSON.

ROC

Datová sada ROC [34] obsahuje 50 snímků sítnic obsahující mikroaneuryzmata určených k trénování neuronové sítě a 50 snímků sítnic určených k testování. Jelikož snímky sítnic určené k testování, narozdíl od snímků určených k trénování, neobsahují anotace, které by obsahovaly lokality mikroaneuryzmat na snímcích, bude tato testovací sada vynechána. Snímky byly pořízeny třemi kamerami a to Topcon NW 100, Topcon NW 200 a kamerou Canon CR5-45NM. Barevné snímky sítnice byly uloženy ve formátu JPG s rozlišením 768 x 576, 1058 x 1061 nebo 1389 x 1383 pixelů a s obrazovým úhlem 45°. Anotace ke všem snímkům jsou obsaženy v jednom souboru ve formátu XML.

SUSTech-SYSU

Datová sada SUSTech-SYSU [25] obsahuje 1219 snímků sítnic od pacientů s diabetickou retinopatií a zdravých pacientů. Obsahuje anotace tvrdých a měkkých exsudátů, které obsahují lokality těchto lézí na snímcích. Společně s anotacemi exsudátů obsahuje anotace optického disku a žluté skvrny. Každý snímek taktéž obsahuje informace, zda se jedná o pravé nebo levé oko a úroveň diabetické retinopatie. Barevné snímky sítnice byly pořízeny fundus kamerou TRC-50DX. Snímky byly uloženy ve formátu JPG s rozlišením 2880 x 2136 pixelů s obrazovým úhlem 50°. Samotné anotace jsou ve formátu XML.

Shrnutí

Pro tuto práci jsou nutné pouze snímky sítnice obsahující jednu z detekovaných patologií. Tyto snímky také musí mít k dispozici soubor obsahující anotace potřebné k lokalizaci patologií na určitém snímku sítnice. Tabulka 4.1 obsahuje shrnutí počtů takových snímků v náležitých datových sadách. Celkem je tedy k dispozici 898 snímků sítnic obsahující mikroaneuryzmata a 1276 snímků sítnic obsahující exsudáty. Datové sady obsahující exsudáty se skládají z tvrdých i měkkých exsudátů.

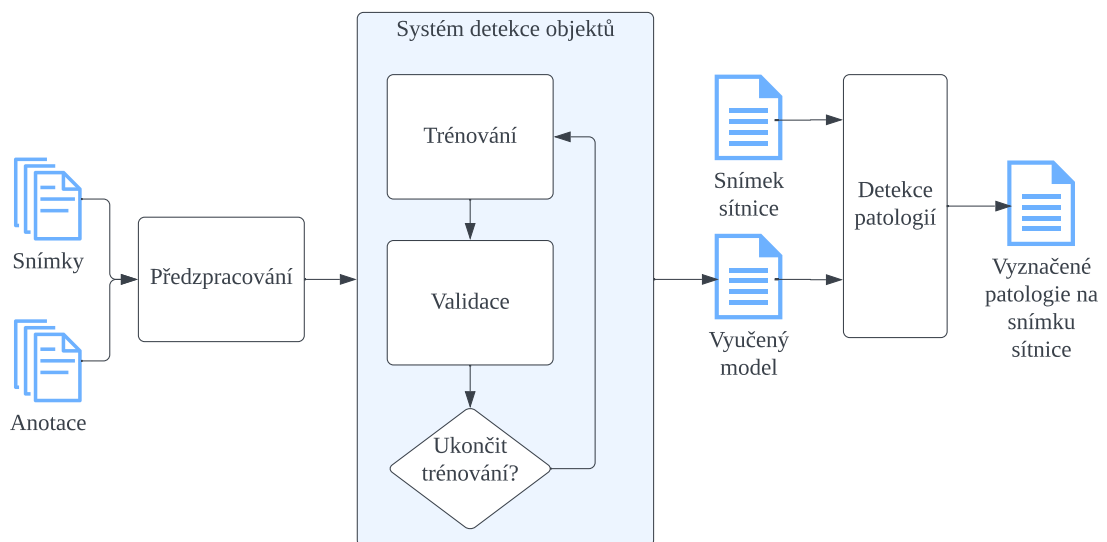
Tabulka 4.1: Počet snímků obsahující dané patologie dle datové sady.

	Mikroaneuryzmata	Exsudáty
DiaRetDB1 V2.1 [21]	81	54
e-ophtha [4]	148	47
OIA-DDR [24]	570	571
FNUSA	62	40
ROC [34]	37	0
SUSTech-SYSU [25]	0	564
Celkem	898	1276

Kapitola 5

Návrh algoritmu detekce patologií na snímcích sítnice

Tato kapitola má za cílem popsat hlavní strukturu navrženého algoritmu pro detekci mikroaneuryzmat a exsudátů na snímcích sítnice. Detekce patologií bude provedena pomocí hlubokého učení na větším počtu datových sad anotovaných barevných snímků sítnic. Obecný diagram závěrečného algoritmu je k dispozici na obrázku 5.1. Snímky budou nejprve adekvátně předzpracovány různými metodami pro zlepšení kvality snímků. Snímky budou také augmentovány pro umělé rozšíření počtu snímků. Jako systém detekce objektů byla vybrána architektura Faster R-CNN [40] pro její slibné výsledky v praxi. Podkapitola 5.1 popisuje problematiku zpracování datových sad anotovaných snímků sítnic. Podkapitola 5.2 popisuje navržené metody předzpracování snímků pro zlepšení výsledků detekování patologií. Podkapitola 5.3 popisuje architekturu samotného systému detekce patologií společně s popisem architektury Faster R-CNN, použitím komponenty příznakové pyramidové sítě [26], předem vyučeného modelu a popisuje samotný proces trénování modelu.



Obrázek 5.1: Obecný diagram navrženého algoritmu detekce patologií na snímcích sítnice.

5.1 Datové sady a jejich zpracování

Jeden z hlavních bodů hlubokého učení je samotné trénování modelu. K tomuto je nutné obstarat větší množství anotovaných dat modelu pro získání adekvátních výsledků během detekování objektů. Navržený algoritmus má k dispozici 898 snímků mikroaneuryzmat a 1276 snímků obsahující tvrdé a měkké exsudáty. Tento počet by měl být dostačující pro dosažení skromných výsledků. Například dle vědeckého článku [48] postačuje k dosažení bodu, kdy se dřívější strmý nárůst přesnosti klasifikace začíná vyrovnávat, 500–1000 snímků. Avšak tato práce se zabývá pouze samotnou klasifikací snímků a je nutné opomenout, že potřeba velikosti datové sady značně závisí na vybrané architektuře k detekování a na charakteristikách detekovaných objektů. Například databáze snímků Microsoft COCO [27] obsahuje přibližně až 270 tisíc segmentovaných osob.

Zpracování datových sad dokáže být značně časově náročné kvůli nezavedenému globálnímu standardu pro formátování anotovaných dat. V dnešní době jsou velmi rozšířené dva formáty anotací snímků pro detekci objektů. Mezi tyto formáty patří použitý formát v datové sadě Microsoft COCO [27] a formát PASCAL VOC zavedený v datových sadách soutěží PASCAL VOC [9] a taktéž použitý v populární datové sadě ImageNet [5]. Z těchto formátů se vyskytuje pouze formát PASCAL VOC v datové sadě OIA-DDR [24] a SUSTech-SYSU [25], jelikož patří k novějším sadám. Ostatní čtyři použité datové sady mají tedy vlastní formát anotací a je nutné implementovat zpracování těchto anotací dle jejich specifikací. Právě tento fakt může mít za následek, že často studie týkající se detekci objektů na snímcích sítnice použijí pouze jednu nebo pár jednotek datových sad. Dle vědeckého článku [49], který se zabývá shrnutím informací týkajících se diabetické retinopatie a metod hlubokého učení, až 40% takových studií použilo pouze jednu veřejně dostupnou datovou sadu snímků sítnic.

Za cílem získání lepších výsledků detekování patologií bylo tedy vybráno větší množství datových sad snímků sítnic. Tento fakt ovšem může mít za následek i potenciálně zhoršení výsledků, jelikož kvalita snímků a způsob anotování patologií se značně liší napříč datovými sadami.

5.2 Předzpracování

Předzpracování dat se provádí u hlubokého učení za cílem odstranění neinformujících dat, zvýraznění detekovaných objektů, rozšíření datové sady nebo za cílem přípravy dat do formátu, který očekává systém detekce objektů. Jakékoliv úpravy provedené na snímcích, které mají za následek přemístění detekovaných objektů, je nutné adekvátně reflektovat během zpracování anotací. Použití hlubokého učení značně snižuje počet nutných metod předzpracování. Metody digitálního zpracování často vyžadují použití většího počtu metod předzpracování (metody předzpracování jsou popsány v podkapitole 3.1). Při použití metod hlubokého učení lze případně plně vynechat použití metod předzpracování, které upravují snímky.

Předzpracování snímků a anotací v navrženém algoritmu se skládá se ze tří kategorií, z nichž dvě mohou být volitelné, jelikož jejich použití potenciálně může zhoršit výsledky detekování a je nutné porovnat výsledky kombinací těchto kategorií. Obecný diagram použitých metod předzpracování se vyskytuje na obrázku 5.2. Odstranění černého pozadí, škálování a normalizace mají za následek pouze nutnou úpravu dat bez většího rizika zhoršení výsledků detekování. Zlepšením kvality snímků lze potenciálně dosáhnout lepších výsledků detekování a augmentace dat slouží k umělému rozšíření velikosti použité datové sady.

Odstranění černého pozadí, škálování a normalizace

První kategorie obsahuje úpravy snímků, které jsou nutné pro správné fungování systému detekcí objektů nebo jejich použití by nemělo zhoršit výsledky detekování.

Odstraněním černého pozadí se pouze změní velikost snímků při zanechání dat v původním stavu. Toto má za následek možnost použití větších rozlišení snímků během trénování systému detekcí. Avšak je nutné garantovat při ořezávání snímků to, že se taktéž neodstraní část sítnice samotné. Tvary sítnic se na snímcích liší dle zařízení, které danou sítnic snímalo. Mezi časté tvary patří kruh a oříznutý kruh na horní a spodní straně. Tyto kruhy mohou obsahovat i menší výběžky, které mohou obsahovat patologie a nejedná se tedy o dokonalé kruhy.

Následuje škálování vstupních snímků. Snímky sítnic mívají vysoké rozlišení a detekované patologie jsou velmi malé objekty na těchto snímcích. Pro účinnější trénování systému budou tedy snímky škálovány na co největší možnou velikost, kterou umožňuje dané zařízení přidělit pro správný chod systému. Architektura Faster R-CNN umožňuje vstup snímků o libovolné velikosti, avšak použití reziduálních neuronových sítí, které potřebují větší velikost paměti, značně omezuje maximální potenciální velikost vstupních snímků.

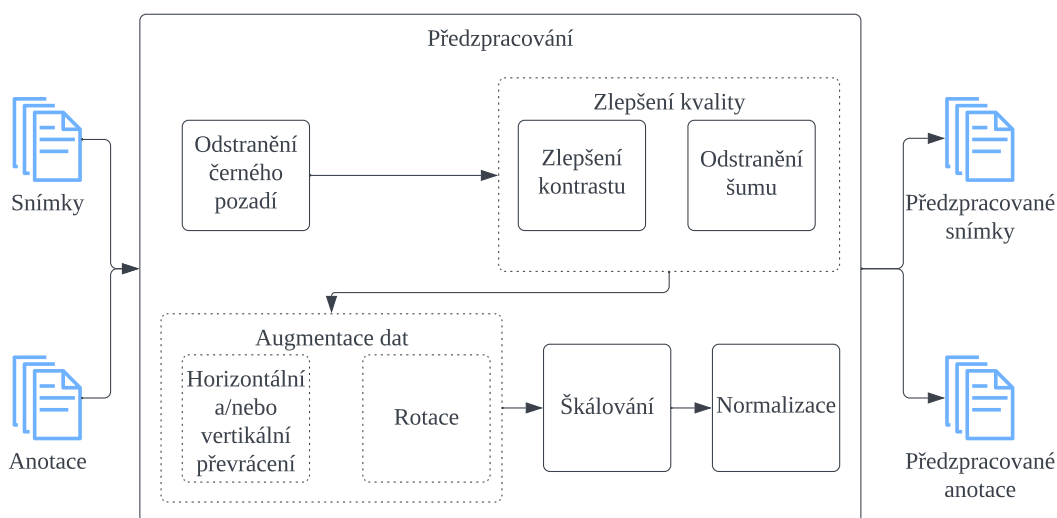
Závěrečným krokem je normalizace dat. V tomto případě se jedná o normalizaci barevných snímků střední a standardní odchylkou za cílem rychlejšího učení a k rychlejšímu dosažení konvergence.

Zlepšení kvality snímků

Na základě analýzy způsobů detekce patologií na snímcích sítnice popsané v kapitole 3 bylo navrženo použití metod pro zlepšení kontrastu a odstranění šumu za cílem zlepšení kvality snímků a tím dosažení lepšího detekování. Adaptivní ekvalizace histogramu (CLAHE) byla vybrána pro její úspěšné použití v jiných pracích. Avšak tato metoda má za potenciální následek amplifikaci existujícího šumu na snímcích. Pro odstranění tohoto problému bude následně použit mediánový filtr pro odstranění tohoto šumu.

Augmentace dat

Augmentací dat lze uměle rozšířit datovou sadu. Při použití menší datové sady lze tuto menší sadu do jisté míry rozšířit a tím pádem zlepšit výsledek trénování modelu. Mezi časté metody například patří náhodný ořez, rotace, převrácení, přidání šumu nebo změna jasu snímku. Je důležité zajistit při použití těchto metod, že rozšířená data budou stále validní. Pro rozšíření datové sady navržený algoritmus bude obsahovat náhodné vertikální nebo horizontální převrácení snímků a bude obsahovat případnou rotaci snímků. Převrácením snímků by data měly zůstat validní, jelikož tvar patologií by měl být do jisté míry náhodný. Rotace snímků patří taktéž mezi časté metody augmentace. Pro zajištění, že snímky po rotaci budou stále validní a budou podobné snímkům v testovací a ověřovací datové sadě, budou rotovány pouze snímky sítnice, které po odstranění černého pozadí, budou mít rozlišení s poměrem stran 1:1 s možností menší odchylky. Tyto augmentace bude možné volitelně přidat do trénování modelu pro pozdější porovnání modelů, které použily nebo nepoužily dané augmentace.




Obrázek 5.2: Obecný diagram navrženého předzpracování dat.

5.3 Systém detekce objektů

Detekce objektů na snímcích se dá rozdělit na dva hlavní podproblémy. Je nutné nalézt potenciální objekty na snímcích a následně klasifikovat tyto objekty do příslušných tříd. V případě detekování mikroaneuryzmat by se jednalo o detekování objektů na snímcích sítnice. A následně by se tyto objekty klasifikovaly buď do třídy mikroaneuryzmat, nebo do třídy reprezentující pozadí sítnice. Problematika detekování objektů na fotografiích je rozsáhlé téma, kterým se zabývají výzkumníci a neustále se řešení této problematiky vyvíjejí. V dnešní době existuje již mnoho architektur založených na hlubokém učení, které prokazují chvályhodné výsledky. Jejich použití garantuje již prokázanou kvalitu výsledků a jsou široce otestovány a porovnány mezi sebou. Výběr architektury záleží na specifikacích právě dané problematiky detekování objektů na snímcích. Během výběru architektury je nutné brát v potaz, zda je důležitější rychlost, přesnost, nebo kompromis do jisté míry mezi těmito dvěma metrikami. Například architektura YOLO [39] je velmi vhodná pro detekování v reálném čase, avšak v případě detekování patologií na snímcích sítnice je přesnost detekování nejdůležitější metrikou. Během výběru architektury pro algoritmus byla vybrána architektura Faster R-CNN dle jejích lepších výsledků v porovnání mezi ostatními architekturami [44]. Bylo navrženo použití architektury Faster R-CNN [40] a to i na základě jejích přesnějších výsledků během detekování menších objektů na snímcích [16].

5.3.1 Architektura Faster R-CNN

Architektura Faster R-CNN [40] je tvořena ze dvou modulů. Prvním modulem je hluboká plně konvoluční síť nazývaná RPN (Region Proposal Networks), která navrhuje regiony obsahující objekty, a druhým modulem je detektor Fast R-CNN [13], který používá tyto navržené regiony. Tyto moduly pracují jako jeden sjednocený systém. Obrázek 5.3 představuje základní diagram této architektury.




Obrázek 5.3: Architektura Faster R-CNN (obrázek adaptovaný z [40]).

Snímky o libovolné velikosti jsou předány jako vstup konvoluční neuronové síti (CNN). Tyto snímky procházejí CNN po střední vrstvě, kde jako výstup CNN se získá mapa příznaků. Tato mapa příznaků následuje do modulu RPN. Cílem RPN je najít předem definovaný počet obdélníkových návrhů regionů, kde se mohou nacházet objekty, s ohodnocením. Dalším důležitým bodem modulu RPN jsou kotvy (anglicky anchors). Základním principem modulu RPN je rovnoměrné rozložení obdélníků o daných velikostech po snímku. Těmto obdélníkům se přezdívá kotvy. RPN následně rozhoduje, zda jednotlivé kotvy obsahují relevantní objekty. Na vybrané kotvy (obdélníky na snímku potenciálně obsahující hledané objekty) a mapy příznaků (získané pomocí konvolučních vrstev) se aplikuje ROI sdružování (anglicky Region of Interest Pooling). ROI sdružování zredukuje velikosti navržených regionů na mapě příznaků do jediné dané velikosti. Tyto upravené data jsou následně vstupem do klasifikátoru, který rozhoduje o třídách daných objektů.

5.3.2 Příznaková pyramidová síť

Za cílem dosažení lepších výsledků detekování objektů bude taktéž použita komponenta příznaková pyramidová síť (FPN) [26] v architektuře Faster R-CNN. FPN je extraktor příznaků, který jako vstup přijímá jedno-škálový obrázek libovolné velikosti a jako výstup vrací proporcionálně velké mapy příznaků na více úrovních plně konvolučním způsobem. Tento proces je nezávislý na páteřních konvolučních architekturách. Působí proto jako obecné řešení pro budování pyramid příznaků uvnitř hlubokých konvolučních sítí.



Obrázek 5.4: Diagram FPN adaptovaný ze [26].

5.3.3 Předem vyučená síť

Trénování modelů hlubokého učení dokáže být značně zdlouhavý a hardwarově náročný proces. Pro urychlení trénování modelů lze použít předem vyučené neuronové sítě. Široce veřejně dostupné předem vyučené modely bývají nejčastěji trénované na datové sadě ImageNet [5]. Datová sada ImageNet není lékařsky orientovaná a je převážně tvořena z obyčejných objektů jako například auto, pes nebo kočka. Neobsahuje tedy patologie na snímcích. Tato skutečnost avšak nezabraňuje použití takového předem vyučeného modelu pro detekování patologií na snímcích sítnice. Práce [32] se zabývala otázkou použití předem takto vyučených modelů na lékařských snímcích a došla k závěru, že použití takových modelů může být účinný způsob, jak přistupovat k úkolům detekování objektů na lékařských snímcích.

5.3.4 Trénování, validace a testování

Životní cyklus modelů popisuje diagram, který je k dispozici na obrázku 5.5. Trénování modelu se skládá z epoch. Během jedné epochy se zpracují všechny trénovací data a je tvořena z trénovacích kroků. Během každého kroku je zpracována jedna dávka (anglicky batch) dat o definované velikosti. Tyto informace platí taktéž pro validaci a testování modelu, avšak bez upravování daného modelu. Zvětšením velikosti dávky dat lze urychlit trénování na úkor použití větší paměti. Jelikož se navržený algoritmus snaží o trénování na snímcích většího rozlišení, bude tato dávka nastavena na velikost o jednom snímku.

Jedna z nejdůležitějších hodnot během trénování je míra učení. Míra učení ovlivňuje, do jaké míry nově získané informace převažují nad starými informacemi, jinými slovy představuje rychlost, jakou se model strojového učení učí. Algoritmus bude umět dynamicky upravovat tuto hodnotu během trénování. Případ použití může být například situace, kdy se model přestal zlepšovat a je vhodné míru učení zmenšit.

Během trénování bude pouze nutné ukládat modely s nejlepšími výsledky. V případě detekování objektů byla vybrána metrika průměrná střední přesnost jako metrika k vybírání nejlepšího modelu. Tedy na konci validace se modul ohodnotí, a jestliže patří mezi nejlepší modely, tak se uloží pro případné pozdější použití.

Algoritmus taktéž bude umět zastavit trénování modelu při dosažení stagnace zlepšování se za cílem snížení výpočetního času použitého během trénování.

Samotná validace slouží k validitě modelu na datech, které modelu nejsou sdíleny během trénování. Tedy se jedná o získání objektivnějších informací reflektující úspěšnost modelu na základě vybraných metrik. Pomocí validace lze adekvátně upravovat hyper-parametry trénování modelu, či vybrat závěrečný model. Jelikož validace hraje velkou roli při vybírání modelu, výsledný model se taktéž závěrečně testuje na testovacích datech, které jsou oddělené od trénovacích a validačních dat. Testování slouží k poskytnutí nezaujatého vyhodnocení konečného modelu.

Trénovací, validační a testovací data datových sad budou rozděleny v poměru 70:20:10. Snímky budou takto vybrány v každé datové sadě. Výběr snímků v datové sadě do jednotlivých kategorií bude náhodný. Počet snímků rozdělen do jednotlivých kategorií je popsán v tabulce 5.1.

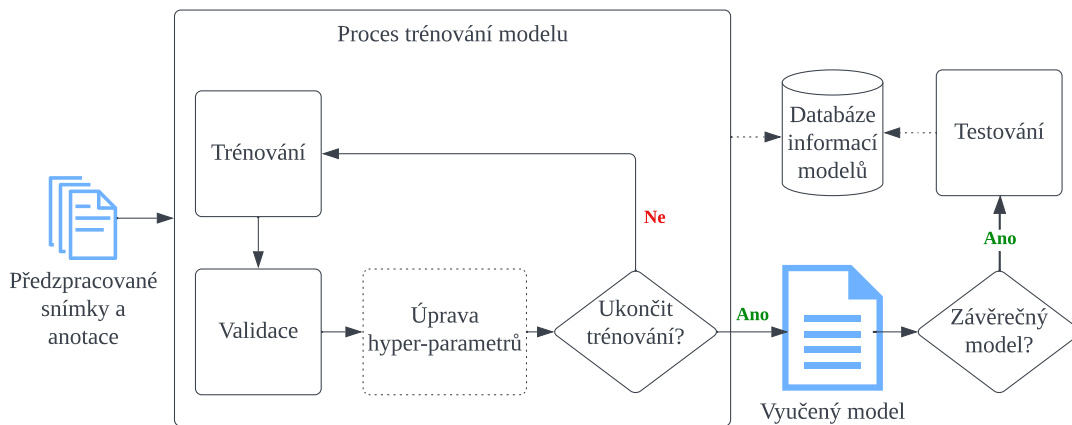
Model je možné trénovat za cílem detekování více tříd objektů. Jelikož budou použity různé datové sady, které anotují různé patologie, je nutné rozdělit trénování pro detekci mikroaneuryzmat a trénování pro detekci exsudátů. Například datová sada anotující pouze exsudáty by mohla obsahovat snímky obsahující mikroaneuryzmata, které by avšak nebyly anotovány, což by mělo za následek zhoršené trénování detekce mikroaneuryzmat. Výsledkem tedy budou dva modely. Jeden vyučený pro detekci mikroaneuryzmat a jeden pro

detekci exsudátů. Při závěrečné detekci patologií na snímcích sítnice stačí pouze snímek předat jako vstup dvěma těmito modelům.

Pro závěrečné porovnání výsledných modelů je nutné uchovávat informace během trénování a validací modelů pro pozdější porovnání. Je tedy taktéž nutné implementovat způsob ukládání těchto informací během trénování. Mezi informace vhodné k vyhodnocení modelů detekování objektů patří přesnost, vzpomnutí (anglicky recall), průměrná přesnost a střední průměrná přesnost [35]. Tyto metriky jsou podrobněji vysvětleny v kapitole 7.

Tabulka 5.1: Počet snímků v jednotlivých kategoriích dle patologií.

	Trénovací sada	Validační sada	Testovací sada
Mikroaneuryzmata	623	186	89
Exsudáty	892	256	128



Obrázek 5.5: Podrobnější proces trénování modelu.

Kapitola 6

Implementace

Závěrečný program byl implementován pro jednoduché a efektivní trénování, ověřování a testování modelů. Umožňuje jednoduché nastavení konfigurace trénování pomocí konfiguračního souboru nebo upravením výchozích hodnot v příslušné třídě. Metriky modelu lze pozorovat v živém čase během trénování nebo zpětně pro případné porovnání modelů. Program taktéž umožňuje vizualizaci jednotlivých snímků, zobrazení jednotlivých kroků předzpracování nebo zobrazení predikcí vyučeného modelu v porovnání se skutečnými umístěními patologií. Všechny tyto části programu slouží pro efektivnější trénování modelů a pro vybírání parametrů trénování na základě získaných metrik jednotlivých modelů. Pomocí vizualizace predikcí lze analyzovat charakteristiky vyučených modelů.

Tato kapitola popisuje způsob implementace jednotlivých komponent algoritmu detekce patologií na snímcích sítnice. Od základního popisu struktury algoritmu až po určité zajímavé pasáže samotné implementace.

6.1 Základní struktura implementace

Algoritmus byl implementován programovacím jazykem Python¹. Programovací jazyk Python byl vybrán na základě jeho snadnějšího používání během implementace v porovnání s ostatními programovacími jazyky a pro jeho rozsáhlé knihovny týkající se strojového učení. Tato skutečnost umožnila rychlejší implementaci základního algoritmu, což mělo za následek přidání více experimentů a přidání vizualizačních prvků. Algoritmus byl implementován pomocí aplikačního rámce PyTorch [37], který byl vybrán pro jeho snadné používání a rozsáhlé dokumentace.

Zdrojový kód byl rozdělen na moduly, kde každý modul má svůj jedinečný význam. Nejdůležitější moduly reprezentují soubory:

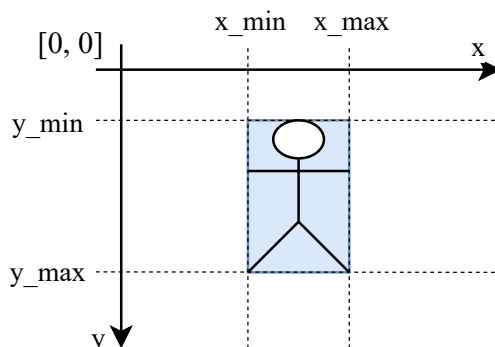
- `main.py` - Zpracování argumentů a případné zpracování konfiguračního souboru. Spuštění programu dle zadaných parametrů.
- `dataset.py` - Obsahuje třídu `Dataset`, která reprezentuje datovou sadu.
- `utils_datasets.py` - Zpracování anotačních souborů dle datové sady.
- `exudates_dataset.py`, `microaneurysms_dataset.py` - Obsahují třídy reprezentující datové sady pro danou patologii.

¹Programovací jazyk Python: <https://www.python.org/>

- `presets.py` - Obsahuje třídy reprezentující předvolby, které jsou tvořeny transformacemi, předzpracování snímků.
- `transforms.py` - Obsahuje třídy představující transformace snímků.
- `faster_rcnn.py` - Obsahuje třídu `FasterRCNN` reprezentující systém detekce Faster R-CNN.
- `train.py` - Nastavení trénování, validace nebo testování a následné spuštění.
- `view.py` - Vizualizace jednotlivých prvků.

6.2 Zpracování anotačních souborů

Při zpracování anotačních souborů různých datových sad je potřebné informace v těchto souborech transformovat do jednoho datového typu. Základem je umět přiřadit k jednomu snímku sítnice umístění jeho jednotlivých patologií a jejich klasifikací. V případě detekování objektů na snímcích stačí k lokalizaci objektu na snímku následující informace: $[x_{\min}, y_{\min}, x_{\max}, y_{\max}]$. Tedy umístění jednotlivých stran objektu na snímku. Grafické znázornění významu je k dispozici na obrázku 6.1. Tomuto datovému typu se přezdívalo ohraničující box (anglicky bounding box). Tento datový typ se bude nadále označovat v textu jako box nebo ohraničující box.



Obrázek 6.1: Informace potřebné k lokalizování objektu na snímku.

Anotační soubory datových sad DiaRetDB1 V2.1 [21], OIA-DDR [24], ROC [34] a SUSTech-SYSU [25] bylo možné jednoduše zpracovat pomocí modulu `etree.ElementTree`², avšak datová sada DiaRetDB1 V2.1 vyžadovala zvýšenou pozornost kvůli svému přístupu k anotačním souborům. Datová sada FNUSA se zpracovává pomocí modulu `json`³. Datová sada e-ophta [4] obsahuje pouze binární masky obsahující vyznačené patologie a bylo nutné implementovat algoritmus řešící tuto problematiku. Při načítání ohraničujících boxů z datových sad e-ophta, FNUSA a DiaRetDB1 V2.1 byly boxy mírně zvětšeny nebo zmenšeny dle vizuální analýzy boxů v těchto datových sadách.


²Modul pro zpracovávání XML dat: <https://docs.python.org/3/library/xml.etree.elementtree.html>

³Modul pro zpracovávání JSON dat: <https://docs.python.org/3/library/json.html>

Zpracování anotačních souborů datové sady DiaRetDB1 V2.1

Patologie v této datové sadě byly anotovány individuálně čtyřmi specialisty. Ke každému snímku sítnice jsou tedy přiděleny až čtyři anotační soubory. Není možné pouze načíst boxy všech anotačních souborů, jelikož každý specialista mohl označit stejné patologie různým způsobem, a tak by se mohl vyskytovat pro jeden výskyt patologie větší počet boxů. Tento problém byl vyřešen pomocí sloučení boxů, které se do jisté míry překrývají.

První jsou načteny všechny boxy všech anotačních souborů k příslušnému snímku. Tyto boxy jsou následně ohodnoceny vůči sobě, zda se překrývají do definované hodnoty. Jestliže se boxy překrývají, jsou tyto boxy sloučeny.




Obrázek 6.2: Příklad sloučení ohraničujících boxů.

Je nutné opomenout i nestandardní anotace této datové sady. Většina ostatní datových sad ukládá ohraničující boxy pomocí čtyř souřadnic, nebo pomocí jednoho bodu a poloměru. Datová sada DiaRetDB1 V2.1 obsahuje anotace, které představují regiony. Mezi tyto regiony patří kruh, elipsa nebo mnohoúhelník. Bylo nutné implementovat algoritmus, který vypočítal ohraničující box těchto regionů.

Zpracování anotačních souborů datové sady e-ophta

V datové sadě e-ophta jsou patologie vyznačeny na binárních maskách. Binární masky jsou grafické soubory o stejném rozlišení jako snímek sítnice, který představují. Každý pixel na tomto obrázku má hodnotu buď jedna, nebo nula. Toto představuje skutečnost, zda daný pixel je nebo není součástí nálezu patologie.

K zjištění větších uskupení bílých pixelů představující jeden určitý výskyt patologie na černém pozadí je použita funkce `findContours` z knihovny OpenCV⁴. Tato funkce vrací list nalezených útvarů. Tyto data stačí následně již minimálně upravit pro získání ohraničujících boxů jednotlivých výskytů patologie na snímku sítnice. Tento proces je znázorněn na obrázku 6.3.



Obrázek 6.3: Příklad získání ohraničujících boxů z binární masky.

⁴Knihovna OpenCV určená k řešení problémů s počítačovým viděním: <https://docs.opencv.org/4.x/>

Zjednodušení zpracování anotačních souborů

Pro zjednodušení načítání snímků a anotačních souborů byly tyto soubory adekvátně přemístěny do různých adresářů a podadresářů. Anotační soubory byly většinou přemístěny do adresářů dle jejich kategorie a to trénování, validace nebo testování pro jednotlivé datové sady. Podrobnosti tohoto přemístění souborů jsou k dispozici v souboru `README.md`.

6.3 Předzpracování dat

Při předzpracování snímků je nutné taktéž adekvátně předzpracovat upravit data z anotačních souborů. Příklad předzpracování dat je na obrázku 6.4.

Odstranění černého pozadí

Odstranění černého pozadí bylo implementováno spočítáním světlejších pixelů v řádku při průchodu od horní nebo spodní hrany nebo v sloupci při průchodu od levé nebo pravé hrany a následným ořezáním snímku.

Všechny pozadí snímků sític mají černý odstín. Algoritmus začíná od hrany snímku, spočítá počet světlejších pixelů v daném řádku nebo sloupci. Jestliže je počet menší než definovaná hodnota, tak pokračuje dále. Jestliže narazí na řádek/sloupec, v kterém se vyskytuje větší počet světlejších pixelů, dost pravděpodobně se jedná o počátek hrany sítě, a tak se uloží hodnota již prošlých řádků/sloupců. Tyto kroky se provedou z každé strany snímku a jako konečný krok je snímek ořezán do dané velikosti. Ohraničující boxy stačí pouze jednoduše upravit odečtením hodnot, o které byl ořezán snímek z levé a horní strany.

Zlepšení kvality

Zlepšení kvality snímku bylo implementováno zlepšením kontrastu metodou CLAHE a následným odstraněním šumu mediánovým filtrem. Byly využity funkce z knihovny OpenCV. Zlepšení kontrastu bylo provedeno funkcí `createCLAHE` a pro aplikování mediánové filtru byla použita funkce `medianBlur` z této knihovny.

Převrácení a rotace

Pro transformace snímků byl použit balíček `torchvision`⁵, který je součástí projektu PyTorch. Tento balíček obsahuje transformace pro snímky. Mezi tyto transformace patří taktéž horizontální a vertikální převrácení snímku nebo rotace snímku.


Jestliže je snímek transformován, je nutné danou transformaci použít i na ohraničující boxy. Převrácení boxů vertikálně či horizontálně je jednoduchá operace. V případě rotace bylo nutné implementovat algoritmus, který je schopný převrátit ohraničující boxy o daný úhel kolem středu snímku.

Škálování a normalizace

Operace škálování a normalizace snímku jsou taktéž součástí balíčku `torchvision`. Avšak samotný systém detekcí již obsahuje tyto operace a automaticky snímky adekvátně škáluje

⁵Balíček `torchvision` se skládá z datových sad, modelových architektur a běžných obrazových transformací pro počítačové vidění: <https://pytorch.org/vision/stable/index.html>

a normalizuje dle zadaných parametrů. V případě trénování neuronové sítě je pro normalizaci snímků nutné vědět hodnoty střední a standardní odchylky barevných kanálů, které se použijí při normalizaci snímků. Byl taktéž implementován výpočet těchto odchylek v případě, že by uživatel chtěl trénovat systém detekcí bez použití předem vyučeného modelu. V případě použití předem vyučeného modelu se doporučuje použití hodnot odchylek podle hodnot, které byly použity při trénování tohoto předem vyučeného modelu.



Obrázek 6.4: Příklad výstupu programu ukazující kroky předzpracování. Dolní řada obsahuje snímky s ohraničujícími boxy.

6.4 Systém detekce objektů a jeho trénování

Samotný systém detekcí objektů byl implementován pomocí třídy `FasterRCNN`, který reprezentuje architekturu Faster R-CNN, dostupné v balíčku `torchvision`. Využití této již implementované třídy značně snížilo čas implementace programu, jelikož architektura Faster R-CNN je komplexnějšího charakteru. Tato třída umožňuje použitím argumentů nastavit nejdůležitější části systému detekcí Faster R-CNN.

Velmi důležitou částí architektury Faster R-CNN jsou konvoluční vrstvy. Program umožňuje výběr modelu reprezentující konvoluční vrstvy a možnost použití komponenty FPN [26]. Toto bylo umožněno balíčkem `torchvision` a knihovnou `Lightning Bolts` [11], které obsahují modely připravené k použití.

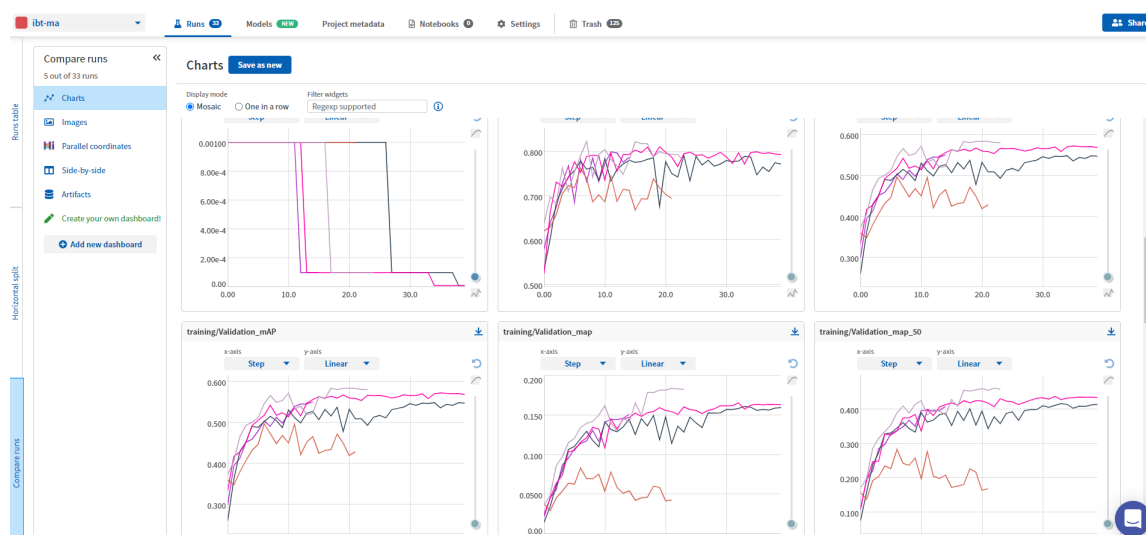
Připravený systém detekcí objektů již stačí pouze trénovat, validovat a závěrečně otestovat. K těmto procesům byla vybrána knihovna `PyTorch Lightning` [10]. Knihovna `PyTorch Lightning` zjednodušuje tyto procesy společně s výběrem hardwaru, na kterém se systém trénuje, mimo jiné.

Soubor `faster_rcnn.py` obsahuje třídu `FasterRCNN` reprezentující systém detekcí Faster R-CNN. Rodičovská třída této třídy je `LightningModule` dostupná z knihovny `PyTorch Lightning`. Mezi její hlavní metody, které bylo nutné přepsat patří metody:

- `__init__` - Inicializace systému detekcí objektů a nastavení parametrů.
- `forward` - Definice chování modelu při jeho volání.

- `training_step` - Definice jednoho kroku trénování.
- `validation_step` - Definice jednoho kroku validace.
- `validation_epoch_end` - Definice chování při ukončení všech validačních kroků. Kalkulace metrik a následné uložení informací.
- `test_step` - Definice jednoho kroku testování.
- `test_epoch_end` - Definice chování při ukončení všech testovacích kroků.
- `configure_optimizers` - Definice optimalizátoru a plánovače změny míry učení.

K ukládání modelů, metrik získaných během vyhodnocování, informací během trénování, validace nebo testování byla použita bezplatná webová služba Neptune⁶. Implementovaný program je schopný zasílat všechny tyto informace přes internet do úložiště služby Neptune, kde lze vyučené modely jednoduše porovnávat.



Obrázek 6.5: Porovnání modelů pomocí webové služby Neptune.

Trénování modelů je značně rychlejší na výkonných grafických kartách v porovnání s trénováním na procesoru. Z důvodů vysokých cen výkonných grafických karet, bylo trénování modelů uskutečněno pomocí služby Google Colaboratory⁷, která umožňuje používání cloudových služeb prostřednictvím Jupyter notebooků⁸. Za cílem rychlejšího trénování, využití větší paměti a používání služeb po delší časové intervaly byla placena verze Colab Pro v hodnotě 9.99 amerických dolarů měsíčně.

Za cílem získání nejlepších výsledků byly nastaveny velikosti škálování snímků co největší. Toto má za následek nutnost používání větší velikosti RAM paměti. Pro použití takových modelů je nutné algoritmus spouštět na zařízeních, které obsahují alespoň přibližně 16 GB RAM paměti nebo grafickou kartu s pamětí s obdobnou pamětí.

⁶Nástroj Neptune pro správu experimentů a spolupráci: <https://neptune.ai/>

⁷Google Colaboratory: <https://colab.research.google.com/>

⁸Jupyter Notebook: <https://jupyter.org/>

6.5 Měření metrik

Měření metrik popsanych v podkapitole 7.2 bylo provedeno pomocí dvou nástrojů.

První nástroj `Object-Detection-Metrics`⁹ [35, 36] umožňuje výpočet nejpoužtějších metrik k vyhodnocení algoritmu detekce objektů. Mezi tyto metriky patří přesnost, recall, průměrná přesnost, průměrná střední přednost. Taktěž umožňuje přístup k celkovým údajům získaných během ohodnocení detekování jako například celkový počet pravdivých nálezů. Pro použití tohoto nástroje bylo pouze nutné adekvátně konvertovat ohraničující boxy do třídy `BoundingBox` poskytnuté tímto nástrojem.

Jak druhý nástroj k vyhodnocení algoritmu byla vybrána knihovna `TorchMetrics` [33]. Tento nástroj podporuje výpočet metrik¹⁰ používaných k vyhodnocení detektorů na datové sadě Microsoft COCO [27].

Kombinace těchto dvou nástrojů umožnila získání základních a pokročilejších metrik používaných k vyhodnocení algoritmu detekce objektů na snímcích.

6.6 Použité nástroje

Pro dosažení zpětné kompatibility s určitými staršími Python balíčky byla vybrána verze Python 3.7.

Spuštění programu na různých zařízeních dokáže být komplikující záležitost kvůli závislosti různých balíčků mezi sebou. Pro vyřešení tohoto problému byl použit nástroj `Pipenv`¹¹. Nástroj `Pipenv` využívá soubory `Pipfile` a `Pipfile.lock` pro sledování verzí potřebných balíčků, které je nutné nainstalovat pro úspěšné spuštění programu, a taktěž umožňuje snadný způsob nainstalování všech potřebných balíčků na aktuálním systému.

Pro spravování verzí samotného zdrojového kódu byl použit nástroj `Git`¹² a pro zálohování byla použita webová služba `GitHub`¹³.

K vizualizaci určitých aspektů programu byla použita knihovna `Matplotlib`¹⁴ v kombinaci s funkcí `draw_bounding_boxes` dostupné z balíčku `torchvision`. K vizualizaci statistických grafů byla využita knihovna `seaborn`¹⁵.

Metoda k-shlukování, použita během analýzy anotačních dat v kapitole 7.1, byla využita pomocí třídy `KMeans`, která je k dispozici v knihovně `scikit-learn`¹⁶.

⁹Nástroj `Object-Detection-Metrics`: <https://github.com/rafaelpadilla/Object-Detection-Metrics>

¹⁰Metriky vyhodnocování detektorů databáze COCO: <https://cocodataset.org/#detection-eval>

¹¹Nástroj `Pipenv`: <https://pipenv.pypa.io/en/latest/>

¹²Systém správy verzí `Git`: <https://git-scm.com/>

¹³Webová služba `GitHub`: <https://github.com/>

¹⁴`Matplotlib`: vizualizace s Pythonem: <https://matplotlib.org/>

¹⁵`Seaborn`: vizualizace dat: <https://seaborn.pydata.org/>

¹⁶Knihovna strojového učení `scikit-learn`: <https://scikit-learn.org/stable/>

Kapitola 7

Testování a vyhodnocení algoritmu


Tato kapitola se zabývá vyhodnocením algoritmu detekce mikroaneuryzmat a exsudátů. Následující podkapitola 7.1 popisuje analýzu ohraničujících boxů za cílem dosáhnout přesnějších výsledků, jelikož během vývoje a testování byla zjištěna potřeba pro dosáhnout lepších výsledků pomocí úpravy parametrů systému detekce. Podkapitola 7.2 vysvětluje použité metriky během vyhodnocení. Podkapitola 7.3 shrnuje dosažené výsledky a obsahuje podrobnější vyhodnocení a porovnání vyučených modelů s publikovanými články.

7.1 Analýza ohraničujících boxů


Jedním z hlavních parametrů systému detekce založeném na architektuře Faster R-CNN jsou velikosti kotev. Na snímku jsou rovnoměrně umístěny body. Do každého bodu jsou následně vloženy kotvy daných velikostí. Modul RPN následně předpovídá, zda dané kotvy obsahují relevantní objekty. Byla provedena analýza ohraničujících boxů patologií za cílem přesnějšího nastavení velikostí těchto kotev.

Histogram ohraničujících boxů

Grafy 7.1 a 7.2 znázorňují ohraničující boxy dle jejich šířky a výšky procentuálně ke šířce nebo výšce snímku sítnice. Snímkům sítnice jsou nejprve odstraněny černé pozadí před následným zpracováním. Na histogramech lze vidět, že značné množství ohraničujících boxů se vyskytuje na počátku grafu a radikálně se množství následně zmenšuje. Taktéž lze vidět menší množství boxů s velmi větší plochou v porovnání s ostatními boxy. Tyto ohraničující boxy lze považovat za anomálie nebo chybně provedené anotace patologií. Celkově se vyskytuje přibližně 20 tisíc ohraničujících boxů mikroaneuryzmat a 65 tisíc ohraničujících boxů exsudátů napříč všemi datovými sadami.




Obrázek 7.1: Graf velikostí ohraničujících boxů mikroaneuryzmat.




Obrázek 7.2: Graf velikostí ohraničujících boxů exsudátů.

Odhad hustoty jádra

Metodou odhadu hustoty jádra (anglicky Kernel Density Estimation zkráceně KDE) byla následně zjištěna pravděpodobnost nálezů ohraničujících boxů v rámci grafu. U mikroaneuryzmat byla vybrána hodnota 3 % jako prahová hodnota na obou osách pro výběr ohraničujících boxů pro následnou analýzu pomocí k-shlukování. U exsudátů pro jejich obecně větší velikost byla vybrána hodnota 30 %. Tyto prahové hodnoty obsahují přibližně 97 % mikroaneuryzmat a 99 % exsudátů.




Obrázek 7.3: Graf ohraničujících boxů mikroaneuryzmat pomocí metody KDE.




Obrázek 7.4: Graf ohraničujících boxů exsudátů pomocí metody KDE.

K-shlukování

Posledním krokem byla analýza ohraničujících boxů pomocí k-shlukování, která je znázorněna na obrázcích 7.5 a 7.6. Komponenta FPN používá pět různých velikostí kotev v rámci implementace a bylo tedy vybráno pět skupin při použití k-shlukování. Pro závěrečný výběr velikostí byly vybrány koordinace těžišť, které byly případně pouze zaokrouhleny nebo byly zprůměrovány hodnotou výšky a šířky v rámci jedné hodnoty těžiště. Pomocí této analýzy byly vybrány hodnoty 8, 12, 16, 22 a 26 pro určení velikostí kotev u detekování mikroaneuryzmat. A hodnoty 8, 22, 50, 100 a 200 byly vybrány jako velikosti kotev pro detekování exsudátů. Tyto hodnoty byly vybrány na základě maximální velikosti strany snímku po provedení škálování. U mikroaneuryzmat se jedná o maximální velikost 1300 pixelů a v případě exsudátů o velikost 850–900 pixelů.



Obrázek 7.5: Analýza ohraničujících boxů mikroaneuryzmat pomocí k-shlukování se zvýrazněními těžišti po odstranění nadměrně rozměrných boxů.



Obrázek 7.6: Analýza ohraničujících boxů exsudátů pomocí k-shlukování se zvýrazněními těžišti po odstranění nadměrně rozměrných boxů.

7.2 Metriky hodnocení algoritmů detekce objektů

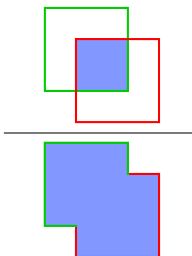
Mezi nejběžnější a nejpoblárnější metriku k vyhodnocení algoritmů detekce objektů se používá průměrná přesnost. K vysvětlení této metriky je nutné popsat základní koncepty této metriky. Tato podkapitola je částečně převzata z [35]. Detekce objektu algoritmem se dá vyhodnotit následujícími způsoby:

- Skutečně pozitivní (TP): Správná detekce pravdivého ohraničujícího boxu.
- Falešně pozitivní (FP): Nesprávná detekce neexistujícího objektu nebo nesprávně umístěná detekce existujícího objektu.
- Falešně negativní (FN): Nebyl detekován pravdivý ohraničující box.

Je nutné opomenout, že skutečně negativní (TN) nález nelze aplikovat při vyhodnocování algoritmů detekce objektů. Tato metrika je však často používána při hodnocení klasifikátorů. Avšak v případě detekce objektů se tato metrika nelze jednoduše aplikovat. Skutečně negativní nález představuje všechny ohraničující boxy na snímku, které by se neměly detekovat. A tento počet může být nekonečný, jelikož tvary těchto boxů mohou být jakékoliv.

Při vyhodnocování detekování objektů je taktéž nutné definovat, co je správná a nesprávná detekce. Často používána metoda je průnik nad sjednocením (IoU). IoU je měření založené na Jaccardovém indexu, což je statistika používaná pro měření podobnosti a rozmanitosti souborů vzorků. IoU měří poměr mezi překrývající se oblastí předpovězeným ohraničujícím boxem B_p a pravdivostním ohraničujícím boxem B_{gt} .

$$J(B_p, B_{gt}) = IoU = \frac{\text{obsah}(B_p \cap B_{gt})}{\text{obsah}(B_p \cup B_{gt})} \quad (7.1)$$

$$IoU = \frac{\text{Obsah pr\u00fAniku}}{\text{Obsah sjednocen\u00ed}}$$


Obrázek 7.7: Graficky znázorněný průnik nad sjednocením.

Porovnáním hodnoty IoU s prahovou hodnotou T můžeme klasifikovat detekci jako správnou nebo nesprávnou. Jestliže je IoU menší nebo se rovná hodnotě T , detekce se klasifikuje jako správná a v opačném případě se detekce klasifikuje jako nesprávná.

Senzitivita patří mezi časté metriky a je taktéž použita v této práci. Rovnice jejího výpočtu je stejná jako rovnice výpočtu metriky recall a jedná se o rovnici 7.3. V této práci senzitivita představuje procento detekovaných nálezů patologií z celkového počtu nálezů patologií na všech snímcích.

7.2.1 Přesnost a recall

K vyhodnocení algoritmu je vhodné použít metriky přesnost a recall. Každá tato metrika popisuje důležitou charakteristiku algoritmu.

Přesnost je schopnost modelu detekovat pouze skutečné objekty. Tedy je to poměr mezi správnými detekcemi algoritmu a všemi detekcemi algoritmu 7.2.

Recall je schopnost modelu detekovat všechny skutečné existující objekty. Je to poměr mezi správnými detekcemi algoritmem a všemi pravdivými ohraničujícími boxy 7.3.

$$\text{Přesnost} = \frac{TP}{TP + FP} = \frac{\text{Skutečně pozitivní nálezy}}{\text{Skutečně pozitivní nálezy} + \text{Falešně pozitivní nálezy}} \quad (7.2)$$

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{\text{Skutečně pozitivní nálezy}}{\text{Skutečně pozitivní nálezy} + \text{Falešně negativní nálezy}} \quad (7.3)$$

Tyto metriky osamotě nerepresentují objektivně výkonnost algoritmu. Necht existuje snímek o deseti objektech. Jestliže by algoritmus vytvořil jednu správnou predikci, přesnost tohoto algoritmu by byla 100 %. Jestliže by algoritmus vytvořil tisíc predikcí a součástí nich by detekoval všechny objekty, recall tohoto algoritmu by byla 100 %. V praxi je cílem dosáhnout jistého kompromisu mezi těmito metrikami. Většinou dochází ke zvýšení přesnosti na úkor metriky recall a naopak.

Jelikož tyto dvě metriky spolu úzce souvisí, je běžné je prezentovat společně pomocí grafu. Tento graf se často uvádí pod názvem PR křivka.

7.2.2 Průměrná přesnost

Obecná definice průměrné přesnosti (AP) je obsah plochy pod křivkou PR. Jelikož hodnoty přesnosti a recall jsou v rozsahu od 0 do 1, tak i hodnota AP je v tomto rozsahu taktéž. Mějme funkci p vracející hodnotu přesnosti pro danou hodnotu metriky recall r :

$$AP = \int_0^1 p(r) dr \quad (7.4)$$

Přesnější definice AP závisí na způsobu interpolace bodů křivky PR. Mezi nejčastější metody interpolace patří interpolace všech bodů, jedenácti bodů nebo 101 bodů křivky.

Střední průměrná přesnost

Jelikož automatizované detektory většinou detekují více tříd objektů, je užitečné ohodnotit detektor pomocí střední průměrné přesnosti. Střední průměrná přesnost (mAP) je metrika používaná k měření přesnosti detektorů objektů ve všech třídách. Metrika mAP je tedy průměr všech AP ze všech tříd. Mějme N detekovaných tříd, kde AP_i je AP v třídě i :

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (7.5)$$

7.3 Vyhodnocení algoritmu

V průběhu implementace byly zkoušeny různé metody předzpracování dat či různé hodnoty parametrů systému detekce objektů za cílem dosáhnout přesnějších výsledků.

Trénovací, validační a testovací data datových sad byly rozděleny v poměru 70:20:10. Snímky byly takto vybrány v každé datové sadě. Výběr snímků v datové sadě do jednotlivých kategorií byl náhodný. Počet snímků rozdělen do jednotlivých kategorií je popsán v tabulce 7.1.

Tabulka 7.1: Počet snímků v jednotlivých kategoriích dle patologií.

	Trénovací sada	Validační sada	Testovací sada
Mikroaneuryzmata	623	186	89
Exsudáty	892	256	128

Pro své nejlepší výsledky v porovnání s ostatními neuronovými sítěmi během experimentování a vývoje byla vybrána neuronová síť ResNeXt101 32×8d [55]. Porovnání jednotlivých neuronových sítí se vyskytuje na tabulce 7.2. Samozřejmě se však jedná o kompromis. Trénování této sítě trvá delší dobu a výsledný model zabírá větší množství dat než například při použití klasických reziduálních sítí [14]. V následujících vyhodnocení modelů se právě používala síť ResNeXt101 32×8d. Výběr nejlepších modelů byl proveden na základě metriky mAP s hodnotou prahování IoU 0.35. Menší hodnota prahování byla vybrána za cílem nalezení více nálezů patologií. Jestliže není určeno jinak, metoda předzpracování odstranění černého pozadí byla vždy provedena. Označení AP_t reprezentuje metriku průměrná přesnost (AP) s prahovou hodnotou t pro IoU. Metriky AP_{35} používají interpolaci všech bodů křivky AP pro přesnější výpočet. Ostatní metriky AP dodržují hodnoty použité pro hodnocení datové sady Microsoft COCO [27] a to interpolaci 101 body.

Tabulka 7.2: Porovnání algoritmu s různými neuronovými sítěmi.

	ResNet-34	ResNet-50	ResNet-101	ResNeXt50 32×4d	ResNeXt101 32×8d
Mikroaneuryzmata	0.572	0.564	0.549	0.553	0.579
Tvrdé exsudáty	0.479	0.492	0.471	0.502	0.497
Měkké exsudáty	0.374	0.390	0.348	0.365	0.391

Kapitola 7.1 popisovala analýzu ohraničujících boxů za cílem získání přesnějších výsledků. Bylo provedeno porovnání vyhodnocení modelů při použití hodnot získaných z analýzy oproti hodnotám, které byly vybrány do jisté míry náhodně. Tyto náhodné velikosti byly pouze vybrány na základě faktu, že mikroaneuryzmata jsou menší velikosti a exsudáty jsou větší velikosti. Na tabulce 7.3 lze vidět porovnání modelů před úpravou velikostí kotev na základě analýzy a po úpravě. Tato úprava značně vylepšila přesnost modelu. V případě mikroaneuryzmat se jedná o zlepšení o 3 %. Střední průměrná přesnost (mAP) modelu detekce exsudátů byla celkově zlepšena o 18 %. U detekce měkkých exsudátů se jedná o menší zhoršení. Je pravděpodobné, že počet tvrdých exsudátů převyšuje počet měkkých exsudátů v datových sadách, a tak analýza pomocí k-shlukování převážně vylepšila detekování početnějších nálezů tvrdých exsudátů.

Tabulka 7.3: Porovnání algoritmů před a po úpravě velikostí kotev.

	Před úpravou	Po úpravě
Mikroaneuryzmata	0.560	0.579
Tvrdé exsudáty	0.350	0.497
Měkké exsudáty	0.401	0.391

Přestože dávka dat, která se zpracovává během jednoho trénovacího kroku, byla nastavena na hodnotu jedna, bylo nutné škálovat snímky do velikosti, kterou bylo možné zpracovat s omezeným množstvím paměti grafické karty. Jelikož ohraničující boxy mikroaneuryzmat jsou menší velikosti, bylo možné škálovat snímky mikroaneuryzmat na maximální

velikost strany o 1300 pixelů. Ohraničující boxy exsudátů jsou většího charakteru, a tak bylo možné škálovat snímky exsudátů pouze na maximální velikost strany o 850–900 pixelů.

Systém byl vyučen a ohodnocen na datových sadách s různým předzpracováním nebo odlišnými hodnotami parametrů systému. Následující tabulka 7.4 popisuje hodnocení dle metod předzpracování. Součástí každého předzpracování je odstranění černého pozadí sítě pomocí ořezání snímku. Přestože byly metody předzpracování dat použity za cílem zlepšení výkonnosti algoritmu, modely, které tyto metody použily, mají obecně horší hodnocení.

Tabulka 7.4: Porovnání vyhodnocení algoritmů dle metod předzpracování.

	Pouze ořez	Zelený kanál	Zlepšení kvality	Převrácení	Rotace
Mikroaneuryzmata	0.579	0.471	0.562	0.573	0.497
Tvrdé exsudáty	0.497	0.443	0.476	0.496	0.482
Měkké exsudáty	0.391	0.361	0.403	0.381	0.326

Výkonnost algoritmu

Při detekování patologií na grafické kartě NVIDIA Tesla P100 16 GB byla spočítaná průměrná doba detekování patologií modelem na předzpracovaném snímku. Při detekci mikroaneuryzmat modelem na snímcích o maximální délce strany 1300 pixelů byla průměrná doba výpočtu přibližně 0.44 sekundy. Při detekci exsudátů na snímcích o maximální délce strany 900 pixelů byla průměrná doba výpočtu 0.21 sekundy. Tyto krátké doby výpočtu umožnily větší počet experimentů.


7.3.1 Detekce mikroaneuryzmat

Tato podkapitola obsahuje podrobnější informace nejlepšího modelu detekce mikroaneuryzmat. V tabulce 7.5 se nachází podrobnější vyhodnocení tohoto modelu. Je nutné si povšimnout zhoršeného hodnocení během testování modelu a to až 20 %. PR grafy validace a testování jsou k dispozici na obrázku 7.8. Příklad porovnání detekce modelem a skutečných nálezů je k dispozici na obrázku 7.9.


Model detekuje mikroaneuryzmata s určitou přesností. Mezi časté chybné detekce modelu patří detekce tečkovitých hemoragií, tento problém je velmi častý u automatizovaných detektorů mikroaneuryzmat, avšak následky mikroaneuryzmat a tečkovitých hemoragií jsou do jisté míry obdobné. Ve výjimečných případech dochází taktéž k záměně mikroaneuryzmat u překřížených cév. V častých případech dochází pouze k záměně u regionů vzhledově připomínající mikroaneuryzmata nebo tečkovité hemoragie. Například cévy, které se ztrácejí do ztracena, mohou v určitých bodech být výraznější a vznikne menší červená tečka.

Tabulka 7.5: Vyhodnocení nejlepšího modelu detekce mikroaneuryzmat.

	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}	AP _{small}	AP _{medium}	AP _{large}	Senzitivita
Validace	0.579	0.444	0.099	0.171	0.176	0.035	-	80.2 %
Testování	0.461	0.350	0.076	0.139	0.141	0.087	-	75.3 %



Obrázek 7.8: PR graf validace nalevo a testování napravo modelu detekce mikroaneuryzmat.



Obrázek 7.9: Porovnání anotace a predikce nejlepšího modelu detekce mikroaneuryzmat.

7.3.2 Detekce exsudátů

Tato podkapitola obsahuje podrobnější informace nejlepšího modelu detekce exsudátů. V tabulkách 7.6 a 7.7 se nachází podrobnější vyhodnocení tohoto modelu dle tříd detekovaných objektů. Hodnocení testování je mnohem lepší než u modelu detekce mikroaneuryzmat. Průměrná přesnost detekce měkkých exsudátů je dokonce o 22 % lepší při závěrečném testování než při validaci. Tabulka 7.8 obsahuje již metriku mAP pro porovnání celkového modelu detekce exsudátů. PR grafy validace a testování tohoto modelu jsou k dispozici na obrázku 7.10. Příklad porovnání detekce modelem a skutečných nálezů je k dispozici na obrázku 7.11. Při detekování exsudátů dochází nejčastěji k záměně s jinými světlejšími regiony na snímcích sítnice nebo s jinými světlejšími patologiemi.

Tabulka 7.6: Vyhodnocení modelu detekce exsudátů při detekce tvrdých exsudátů.

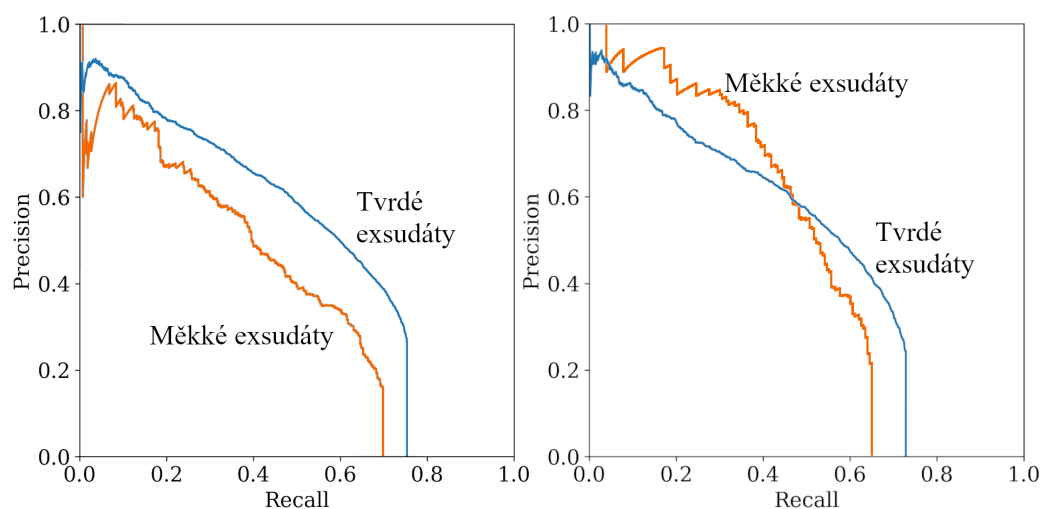
	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}	Senzitivita
Validace	0.4973	0.3756	0.0900	0.1511	75.4 %
Testování	0.4750	0.3511	0.0771	0.1352	72.9 %

Tabulka 7.7: Vyhodnocení modelu detekce exsudátů při detekce měkkých exsudátů.


	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}	Senzitivita
Validace	0.3913	0.3295	0.1356	0.1572	69.7 %
Testování	0.4767	0.4147	0.1387	0.1953	65.0 %

Tabulka 7.8: Vyhodnocení systému detekce tvrdých a měkkých exsudátů.

	mAP ₃₅	mAP ₅₀	mAP ₇₅	mAP _{5..95}	mAP _{small}	mAP _{medium}	mAP _{large}
Validace	0.4443	0.353	0.113	0.154	0.078	0.212	0.105
Testování	0.4759	0.383	0.107	0.165	0.078	0.173	0.170



Obrázek 7.10: PR graf validace nalevo a testování napravo modelu detekce exsudátů.



Obrázek 7.11: Porovnání anotace a predikce nejlepšího modelu detekce exsudátů.

7.3.3 Porovnání modelů s vědeckými články

Práce vyučila modely na základě rozložení datových sad trénování, validace a testování v poměru 70:20:10. Tímto však narušila původní rozložení datové sady OIA-DDR [24], která již obsahovala rozdělení na trénovací, validační a testovací sadu v poměru 50:20:30. Pro objektivní porovnání mezi vyučenými modely a vědeckými články, které použily datovou sadu OIA-DDR v původním rozložení, byly vyučeny taktéž modely se zachovaným rozložením datové sady OIA-DDR. Tyto modely byly vyučeny parametry nejlepších modelů z předchozích podkapitol a jejich datové sady zůstaly stejné až na datovou sadu OIA-DDR. Z této datové sady se však braly v potaz při trénování, validaci a testování pouze snímky obsahující detekované patologie. Model detekce mikroaneuryzmat pouze zpracovával snímky obsahující mikroaneuryzmata a model detekce exsudátů pouze zpracovával snímky obsahující tvrdé nebo měkké exsudáty. Všechny měření použily 101 bodovou interpolaci, jelikož její použití je častější v publikovaných člancích.

Hodnocení modelů s původním rozložením datové sady OIA-DDR

Model detekce mikroaneuryzmat obdržel přibližně podobných výsledků jako původní model detekce mikroaneuryzmat. Při porovnání tabulky nového modelu 7.9 se zachovaným rozložením datové sady OIA-DDR a tabulky původního modelu detekce mikroaneuryzmat 7.5 lze vidět pouze menší změny. Při zachování rozložení datové sady OIA-DDR se převážně navýšil počet snímků testování na úkor snímků trénování. Jelikož tvar mikroaneuryzmat je do jisté míry jednoduchý, tak snížení počtu snímků trénování nezhorsilo radikálně vyučený model.

Tabulka 7.9: Vyhodnocení modelu detekce mikroaneuryzmat se zachovaným rozložením datové sady OIA-DDR.

	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}	AP _{small}	AP _{medium}	Senzitivita
Validace	0.5616	0.4458	0.0945	0.1709	0.1761	0.0332	79.3 %
Testování	0.4841	0.4051	0.0863	0.1606	0.1622	0.1151	77.5 %

V případě detekce exsudátů došlo k většímu zhoršení. Avšak je nutné opomenout, že porovnávat takto modely není zcela objektivní, jelikož byly testovány na rozdílných datech. Původní vyhodnocení modelu na tabulce 7.8 a vyhodnocení nového modelu se zachovaným rozložením datové sady OIA-DDR na tabulce 7.12 se převážně liší ve vyhodnocení detekce měkkých exsudátů, při kterém došlo až ke 30 % zhoršení. Komplexnější tvar exsudátů nejspíš zapříčinil při zmenšení trénovací sady toto velké zhoršení. Podrobnější vyhodnocení dle detekované patologie se vyskytuje na tabulce 7.10 a 7.11.

Tabulka 7.10: Vyhodnocení modelu detekce exsudátů při detekci tvrdých exsudátů se zachovaným rozložením datové sady OIA-DDR.

	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}	Senzitivita
Validace	0.4558	0.3592	0.0660	0.1339	74.7 %
Testování	0.3725	0.2754	0.0509	0.1026	63.0 %

Tabulka 7.11: Vyhodnocení modelu detekce exsudátů při detekci měkkých exsudátů se zachovaným rozložením datové sady OIA-DDR.

	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}	Senzitivita
Validace	0.3980	0.3410	0.1165	0.1460	64.2 %
Testování	0.2858	0.2561	0.0989	0.1201	45.9 %

Tabulka 7.12: Vyhodnocení systému detekce tvrdých a měkkých exsudátů se zachovaným rozložením datové sady OIA-DDR.

	mAP ₃₅	mAP ₅₀	mAP ₇₅	mAP _{5..95}	mAP _{small}	mAP _{medium}	mAP _{large}
Validace	0.4269	0.3501	0.0913	0.1400	0.0600	0.1969	0.0912
Testování	0.3292	0.2657	0.0749	0.1114	0.0484	0.1389	0.1277

Porovnání modelů s vědeckými články

Vyučené modely, které zachovaly rozložení datové sady OIA-DDR, byly následně otestovány pouze na testovací sadě datové sady OIA-DDR a jejich vyhodnocení bylo porováno s vědeckými články. Bylo zjištěno, že vyučené modely mají lepší přesnost než tyto určité publikované články. Podrobnější porovnání se vyskytují na tabulkách 7.13, 7.14 a 7.15.

Jelikož jsou porovnány práce na datové sadě OIA-DDR, byly taktéž vyučeny modely detekce pouze na datové sadě OIA-DDR. Tyto modely k trénování, validaci a testování použily pouze datovou sadu OIA-DDR v původním rozložení. A to za cílem zjištění do jaké míry velmi rozdílné způsoby anotování napříč datovými sadami dokážou potenciálně zhoršit nebo zlepšit přesnost detekce. Tyto modely budou nadále v textu označovány jako modely detekce OIA-DDR.

V případě detekování mikroaneuryzmat bylo možné porovnání s modelem od práce [43], která byla publikovaná v roce 2022. Vyučený model detekce dosáhl hodnoty 0.5416 AP₁₀, zatímco práce [43] dosáhla hodnoty 0.3355 AP₁₀. Modely detekce OIA-DDR, které zpracovávaly pouze snímky datové sady OIA-DDR, dosáhly lepších výsledků při detekci tvrdých exsudátů, zatímco při detekci měkkých exsudátů a mikroaneuryzmat jsou výsledky obdobné vůči modelu, který byl učen na šesti datových sadách. Přestože model detekce OIA-DDR byl trénován na početně menší trénovací sadě, dosáhl lepších výsledků než model trénován na šesti datových sadách. Tyto vyhodnocení nejspíš potvrzují skutečnost, že velmi rozdílné způsoby tvorby anotací napříč datovými sadami mohou zhoršit celkovou přesnost modelů.

Tabulka 7.13: Porovnání detekce mikroaneuryzmat (MA) na testovací sadě OIA-DDR.

	AP ₁₀	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}
Li a ostatní (2019) [24]	0.0004	-	-	-	-
Santos a ostatní (2021) [45]	-	-	0.0028	-	-
Santos a ostatní (2021) [46]	-	-	0.0193	-	-
Hervella a ostatní (2022) [43]	0.3355	-	-	-	-
Model detekce MA	0.5416	0.5076	0.4230	0.0877	0.1670
Model detekce MA OIA-DDR	0.5476	0.5193	0.4429	0.1043	0.1830

Tabulka 7.14: Porovnání detekce tvrdých exsudátů na testovací sadě OIA-DDR.

	AP ₁₀	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}
Li a ostatní (2019) [24]	0.0014	-	-	-	-
Santos a ostatní (2021) [45]	-	-	0.0342	-	-
Santos a ostatní (2021) [46]	-	-	0.0370	-	-
Model detekce EX	0.4280	0.3555	0.2571	0.0511	0.0965
Model detekce EX OIA-DDR	0.4778	0.4225	0.3473	0.0813	0.1399

Tabulka 7.15: Porovnání detekce měkkých exsudátů na testovací sadě OIA-DDR.

	AP ₁₀	AP ₃₅	AP ₅₀	AP ₇₅	AP _{5..95}
Li a ostatní (2019) [24]	0.0000	-	-	-	-
Santos a ostatní (2021) [45]	-	-	0.1000	-	-
Santos a ostatní (2021) [46]	-	-	0.1493	-	-
Model detekce EX	0.2639	0.2600	0.2530	0.1004	0.1215
Model detekce EX OIA-DDR	0.2716	0.2664	0.2457	0.1010	0.1240

7.3.4 Shrnutí vyhodnocení modelů

Po vyhodnocení modelů a během vizuálního porovnávání predikcí modelů a skutečnou pravdou danou anotačními soubory se došlo následujícím závěrům. Přestože počet výskytů mikroaneuryzmat v datových sadách je přibližně trojnásobně menší než počet výskytů exsudátů, došlo k přibližně podobným výsledkům a byly nalezeny podobné problémy v detekci jako u ostatních automatizovaných detektorech.

Výsledky metriky AP u větších hodnot prahování IoU jsou velmi malé. Tohle bylo očekávané pro velmi rozdílné způsoby anotování napříč datovými sadami. Byly nalezeny vyznačené patologie obsahující větší počet patologií nebo vyznačené plochy pro danou patologii byly mnohonásobně větší než skutečné plochy patologie. Tento problém byl povšimnut i na druhé straně spektra. V případě mikroaneuryzmat byly nalezeny ohraničující boxy uvnitř mikroaneuryzmat, a tak neobsahovaly celý nálezní patologii. Anotace nejsou taktéž jednotné ve způsobu vyznačení hranic jednotlivých patologií. Mikroaneuryzmata připomínají vzhledem malé červené tečky, a tak jejich značení bývá přibližně obdobné napříč datovými sadami. Některé hranice mikroaneuryzmat se mohou pouze ztrácet do neznáma, a tak přesné vyznačení hranic je diskutabilní. Exsudáty avšak mají mnohem komplikovanější tvar a bylo povšimnuto velmi rozdílného značení a to zejména v případě značení jednotlivého exsudátu. Hranice exsudátů jsou výraznější než u mikroaneuryzmat, avšak definice jednoho exsudátu je komplikovanější. Tento problém nekonzistentního značení napříč datovými sadami je pochopitelný ze strany specialistů.

Překvapivé bylo taktéž horší vyhodnocení modelů používající různé metody předzpracování. Avšak tato skutečnost může potvrzovat fakt, že metody předzpracování nejsou tolik zapotřebí při použití hlubokého učení k detekování objektů. Rotace snímků může vytvořit snímky, které by se nedaly považovat za validní, a tak horší přesnost při použití této transformace je pochopitelná. Použití rotace bylo použito z důvodu myšlenky, že tvar patologií je do jisté míry náhodný a nezávisí na úhlu sítnice. Převrácením snímků se dostalo téměř totožné přesnosti jako při pouze odstranění černého pozadí. Je možné, že při dalším experimentování parametrů trénování a modelů, by se daly zlepšit výsledky hodnocení.

Další problém se týká porovnání samotného algoritmu s ostatními algoritmy navrženými jinými vědeckými pracemi. Tato práce použila jako hlavní metriku k vyhodnocení algoritmu průměrnou přesnost. Jedná se o jednu z nejvíce používaných metrik při detekování objektů na snímcích. Byla taktéž použita v soutěžích Pascal VOC [9] nebo například při hodnocení algoritmů detekujících objekty v datové sadě Microsoft COCO [27]. Je taktéž použita v publikaci k datové sadě snímků sítnic OIA-DDR [24]. Avšak většina ostatních prací, které se zabývaly detekcí patologií na snímcích sítnice, použily jiné metriky, které nejsou zrovna ideální k objektivnímu ohodnocení algoritmu detekce objektů jako například specifčnost a to kvůli skutečně negativním nálezům, které se nedají adekvátně brát v potaz při detekci objektů. Tyto ostatní práce například používají jako skutečně negativní nález každý pixel, který není součástí detekované patologie. Toto má za následek vysoké hodnoty metrik, které používají skutečně negativní nález v rámci výpočtu.

Porovnání modelů s vědeckými pracemi, které použily stejnou metriku k vyhodnocení modelů, ukázalo, že vyučené modely touto prací prezentují chvályhodné výsledky. Taktéž se došlo k závěru, že velmi rozdílné způsoby anotací napříč datovými sadami mohou zhoršit celkovou přesnost modelů. Při výběru datových sad v budoucnosti je tedy nutné brát v potaz kvalitu snímků, ale i tak také způsob anotování patologií na snímcích.

Kapitola 8

Závěr

Cílem této práce bylo navrhnout a implementovat algoritmus detekce mikroaneuryzmat a exsudátů na základě studie těchto patologií a jejich detekcí a následné vyhodnocení tohoto algoritmu.

Práce sepsala nejdůležitější poznatky anatomie oční koule, způsobů snímání sítnice a popsala charakteristiky detekovaných patologií. Byl navržen algoritmus na základě hlubokého učení a bylo použito větší množství datových sad snímků sítnic. Algoritmus byl navržen za cílem přesnějších výsledků, a tak obsahuje populární praxí ověřené komponenty a větší počet možných transformací dat. Dle vybrané architektury proběhla analýza dat datových sad, podle které se upravily následně parametry algoritmu za cílem dosažení lepších výsledků. Algoritmus byl vyhodnocen základě populárních metrik používaných k hodnocení algoritmů detekce objektů na snímcích. Výsledný algoritmus dosáhl hodnoty 0.47 mAP při detekování mikroaneuryzmat a hodnoty 0.48 mAP při detekování exsudátů. Po úpravě datových sad pro objektivní porovnání vyučených modelů touto prací s publikovanými články, bylo zjištěno, že vyučené modely touto prací prezentují chvályhodné výsledky a implementovaný algoritmus k učení modelů je schopen učit modely s velmi dobrou přesností.

Práce by následně v budoucnu mohla být rozšířena o větší počet experimentů a o rozsáhlejší analýzu dat. Tato práce převážně experimentovala s reziduálními neuronovými sítěmi, a tak by bylo vhodné vyzkoušet i další neuronové sítě. Taktéž je možné vyzkoušet jiné architektury systému detekce a výsledné hodnocení porovnat mezi sebou. Důležitou složkou hlubokého učení jsou datové sady. Bylo by vhodné použít datové sady podrobněji zanalyzovat, jelikož bylo zjištěno, že způsoby vyznačování patologií specialisty dokážou být velmi rozdílné a potenciálně mohou vést k horším výsledkům. V nejlepším případě by bylo vhodné zavést globální jednotný způsob vyznačování patologií specialisty za cílem dosažení lepších výsledků podobnými modely.

Hluboké učení v rámci detekování patologií na snímcích sítnice ukazuje slibné výsledky a má rozhodně potenciál dosáhnout vynikajících výsledků v budoucnosti.

Literatura

- [1] ABRAMOFF, M. D., GARVIN, M. K. a SONKA, M. Retinal Imaging and Image Analysis. *IEEE Reviews in Biomedical Engineering*. Institute of Electrical and Electronics Engineers (IEEE). 2010, sv. 3, s. 169–208. DOI: 10.1109/rbme.2010.2084567. Dostupné z: <https://doi.org/10.1109/rbme.2010.2084567>.
- [2] AMIN, J., SHARIF, M. a YASMIN, M. A Review on Recent Developments for Detection of Diabetic Retinopathy. *Scientifica*. Hindawi Limited. 2016, sv. 2016, s. 1–20. DOI: 10.1155/2016/6838976. Dostupné z: <https://doi.org/10.1155/2016/6838976>.
- [3] ASHTON, N., KOK, D. a FOULDS, W. S. Ocular pathology in macroglobulinaemia. *The Journal of Pathology and Bacteriology*. Wiley. říjen 1963, sv. 86, č. 2, s. 453–461. DOI: 10.1002/path.1700860220. Dostupné z: <https://doi.org/10.1002/path.1700860220>.
- [4] DECENCIÈRE, E., CAZUGUEL, G., ZHANG, X., THIBAUT, G., KLEIN, J.-C. et al. TeleOphta: Machine learning and image processing methods for teleophthalmology. *IRBM*. Elsevier BV. duben 2013, sv. 34, č. 2, s. 196–203. DOI: 10.1016/j.irbm.2013.01.010. Dostupné z: <https://doi.org/10.1016/j.irbm.2013.01.010>.
- [5] DENG, J., DONG, W., SOCHER, R., LI, L.-J., LI, K. et al. ImageNet: A large-scale hierarchical image database. In: *2009 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, červen 2009. DOI: 10.1109/cvpr.2009.5206848. Dostupné z: <https://doi.org/10.1109/cvpr.2009.5206848>.
- [6] DUBOW, M., PINHAS, A., SHAH, N., COOPER, R. F., GAN, A. et al. Classification of Human Retinal Microaneurysms Using Adaptive Optics Scanning Light Ophthalmoscope Fluorescein Angiography. *Investigative Ophthalmology & Visual Science*. Association for Research in Vision and Ophthalmology (ARVO). Březen 2014, sv. 55, č. 3, s. 1299. DOI: 10.1167/iovs.13-13122. Dostupné z: <https://doi.org/10.1167/iovs.13-13122>.
- [7] DUKE, J. R., WILKINSON, C. P. a SIGELMAN, S. Retinal microaneurysms in leukaemia. *British Journal of Ophthalmology*. BMJ. květen 1968, sv. 52, č. 5, s. 368–374. DOI: 10.1136/bjo.52.5.368. Dostupné z: <https://doi.org/10.1136/bjo.52.5.368>.
- [8] DYLEVSKÝ, I. *Somatologie: pro předmět Základy anatomie a fyziologie člověka*. 3. přepracované a doplněné vydání. Praha: Grada Publishing, 2019. ISBN 978-80-271-2111-3.

- [9] EVERINGHAM, M., VAN GOOL, L., WILLIAMS, C. K. I., WINN, J. a ZISSERMAN, A. The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*. Jun 2010, sv. 88, č. 2, s. 303–338. DOI: 10.1007/s11263-009-0275-4. ISSN 1573-1405. Dostupné z: <https://doi.org/10.1007/s11263-009-0275-4>.
- [10] FALCON, W., BOROVEC, J., WÄLCHLI, A., EGGERT, N., SCHOCK, J. et al. *PyTorchLightning/pytorch-lightning: 0.7.6 release*. Zenodo, 2020. DOI: 10.5281/ZENODO.3828935. Dostupné z: <https://zenodo.org/record/3828935>.
- [11] FALCON, W. a CHO, K. A Framework For Contrastive Self-Supervised Learning And Designing A New Approach. arXiv. 2020. DOI: 10.48550/ARXIV.2009.00104. Dostupné z: <https://arxiv.org/abs/2009.00104>.
- [12] FRIEDENWALD, J. S. Diabetic Retinopathy. *American Journal of Ophthalmology*. Elsevier Inc. 1950, sv. 33, č. 8, s. 1187–1199. DOI: [https://doi.org/10.1016/0002-9394\(50\)90988-3](https://doi.org/10.1016/0002-9394(50)90988-3). ISSN 0002-9394. Dostupné z: <https://www.sciencedirect.com/science/article/pii/0002939450909883>.
- [13] GIRSHICK, R. *Fast R-CNN*. arXiv, 2015. DOI: 10.48550/ARXIV.1504.08083. Dostupné z: <https://arxiv.org/abs/1504.08083>.
- [14] HE, K., ZHANG, X., REN, S. a SUN, J. *Deep Residual Learning for Image Recognition*. arXiv, 2015. DOI: 10.48550/ARXIV.1512.03385. Dostupné z: <https://arxiv.org/abs/1512.03385>.
- [15] HLOŽÁNEK, M. a BRŮNOVÁ, B. *Přístrojová technika v oftalmologii*. Praha: Univerzita Karlova, 2. lékařská fakulta, 2006. ISBN 80-902160-9-9.
- [16] HUANG, J., RATHOD, V., SUN, C., ZHU, M., KORATTIKARA, A. et al. *Speed/accuracy trade-offs for modern convolutional object detectors*. arXiv, 2016. DOI: 10.48550/ARXIV.1611.10012. Dostupné z: <https://arxiv.org/abs/1611.10012>.
- [17] HÄGGSTRÖM, M. *Fundus photograph of normal right eye* [online]. 2012 [cit. 2021-12-19]. Dostupné z: https://commons.wikimedia.org/wiki/File:Fundus_photograph_of_normal_right_eye.jpg.
- [18] JELINEK, H. a CREE, M. J. *Automated image detection of retinal pathology*. Boca Raton, Florida, Spojené státy americké: CRC Press, 2010. ISBN 978-0-8493-7556-9.
- [19] JOSHI, S. a KARULE, P. A review on exudates detection methods for diabetic retinopathy. *Biomedicine & Pharmacotherapy*. Elsevier BV. leden 2018, sv. 97, s. 1454–1460. DOI: 10.1016/j.biopha.2017.11.009. Dostupné z: <https://doi.org/10.1016/j.biopha.2017.11.009>.
- [20] KAUPPI, T., KALESNYKIENE, V., KAMARAINEN, J.-K., LENSU, L., SORRI, I. et al. The DIARETDB1 diabetic retinopathy database and evaluation protocol. In: *Proceedings of the British Machine Vision Conference 2007*. British Machine Vision Association, 2007. DOI: 10.5244/c.21.15. Dostupné z: <https://doi.org/10.5244/c.21.15>.
- [21] KAUPPI, T., KÄMÄRÄINEN, J.-K., LENSU, L., KALESNYKIENE, V., SORRI, I. et al. Constructing Benchmark Databases and Protocols for Medical Image Analysis:

- Diabetic Retinopathy. *Computational and Mathematical Methods in Medicine*. Hindawi Limited. 2013, sv. 2013, s. 1–15. DOI: 10.1155/2013/368514. Dostupné z: <https://doi.org/10.1155/2013/368514>.
- [22] KOHNER, E. M., SLEIGHTHOLM, M., BERGENSTAL, R., MORSE, P., RUBENSTEIN, A. et al. Does Microaneurysm Count Reflect Severity of Early Diabetic Retinopathy? *Ophthalmology*. Elsevier BV. Květen 1986, sv. 93, č. 5, s. 586–589. DOI: 10.1016/s0161-6420(86)33692-3. Dostupné z: [https://doi.org/10.1016/s0161-6420\(86\)33692-3](https://doi.org/10.1016/s0161-6420(86)33692-3).
- [23] KŘIVÁNKOVÁ, M. *Somatologie: pro střední zdravotnické školy*. 2., doplněné vydání. Praha: Grada Publishing, 2019. Sestra (Grada). ISBN 978-80-271-0695-0.
- [24] LI, T., GAO, Y., WANG, K., GUO, S., LIU, H. et al. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening. *Information Sciences*. Elsevier BV. říjen 2019, sv. 501, s. 511–522. DOI: 10.1016/j.ins.2019.06.011. Dostupné z: <https://doi.org/10.1016/j.ins.2019.06.011>.
- [25] LIN, L., LI, M., HUANG, Y., CHENG, P., XIA, H. et al. The SUSTech-SYSU dataset for automated exudate detection and diabetic retinopathy grading. *Scientific Data*. Springer Science and Business Media LLC. listopad 2020, sv. 7, č. 1. DOI: 10.1038/s41597-020-00755-0. Dostupné z: <https://doi.org/10.1038/s41597-020-00755-0>.
- [26] LIN, T.-Y., DOLLÁR, P., GIRSHICK, R., HE, K., HARIHARAN, B. et al. *Feature Pyramid Networks for Object Detection*. arXiv, 2016. DOI: 10.48550/ARXIV.1612.03144. Dostupné z: <https://arxiv.org/abs/1612.03144>.
- [27] LIN, T.-Y., MAIRE, M., BELONGIE, S., BOURDEV, L., GIRSHICK, R. et al. *Microsoft COCO: Common Objects in Context*. arXiv, 2014. DOI: 10.48550/ARXIV.1405.0312. Dostupné z: <https://arxiv.org/abs/1405.0312>.
- [28] LUCIE PŘIKRYLOVÁ, L. S. a. *Ošetřovatelství pro střední zdravotnické školy: Dermatovenerologie, oftalmologie, ORL, stomatologie*. 2., doplněné vydání. Praha: Grada, 2014. Sestra (Grada). ISBN 978-80-247-4342-4.
- [29] MAYYA, V., S., S. K. a KULKARNI, U. Automated microaneurysms detection for early diagnosis of diabetic retinopathy: A Comprehensive review. *Computer Methods and Programs in Biomedicine Update*. Elsevier BV. 2021, sv. 1, s. 100013. DOI: 10.1016/j.cmpbup.2021.100013. Dostupné z: <https://doi.org/10.1016/j.cmpbup.2021.100013>.
- [30] MCLEOD, D., MARSHALL, J., KOHNER, E. M. a BIRD, A. C. The role of axoplasmic transport in the pathogenesis of retinal cotton-wool spots. *British Journal of Ophthalmology*. BMJ Publishing Group Ltd. 1977, sv. 61, č. 3, s. 177–191. DOI: 10.1136/bjo.61.3.177. ISSN 0007-1161. Dostupné z: <https://bj.o.bmj.com/content/61/3/177>.
- [31] MIZUTANI, M., KERN, T. S. a LORENZI, M. Accelerated death of retinal microvascular cells in human and experimental diabetic retinopathy. *Journal of Clinical Investigation*. American Society for Clinical Investigation. Červenec 1996,

- sv. 97, č. 12, s. 2883–2890. DOI: 10.1172/jci118746. Dostupné z: <https://doi.org/10.1172/jci118746>.
- [32] MORID, M. A., BORJALI, A. a FIOLE, G. D. A scoping review of transfer learning research on medical image analysis using ImageNet. *Computers in Biology and Medicine*. Elsevier BV. leden 2021, sv. 128, s. 104115. DOI: 10.1016/j.compbiomed.2020.104115. Dostupné z: <https://doi.org/10.1016/j.compbiomed.2020.104115>.
- [33] NICKI SKAFTE DETLEFSEN, JIRI BOROVEC, JUSTUS SCHOCK, ANANYA HARSH, TEDDY KOKER et al. *TorchMetrics - Measuring Reproducibility in PyTorch*. Únor 2022. DOI: 10.21105/joss.04101. Dostupné z: <https://github.com/PyTorchLightning/metrics>.
- [34] NIEMEIJER, M., GINNEKEN, B. van, CREE, M. J., MIZUTANI, A., QUELLEC, G. et al. Retinopathy Online Challenge: Automatic Detection of Microaneurysms in Digital Color Fundus Photographs. *IEEE Transactions on Medical Imaging*. 2010, sv. 29, č. 1, s. 185–195. DOI: 10.1109/TMI.2009.2033909. Dostupné z: <https://doi.org/10.1109/tmi.2009.2033909>.
- [35] PADILLA, R., NETTO, S. L. a SILVA, E. A. B. da. A Survey on Performance Metrics for Object-Detection Algorithms. In: *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*. IEEE, červenec 2020. DOI: 10.1109/iwSSIP48289.2020.9145130. Dostupné z: <https://doi.org/10.1109/iwSSIP48289.2020.9145130>.
- [36] PADILLA, R., PASSOS, W. L., DIAS, T. L. B., NETTO, S. L. a SILVA, E. A. B. da. A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. *Electronics*. MDPI AG. leden 2021, sv. 10, č. 3, s. 279. DOI: 10.3390/electronics10030279. Dostupné z: <https://doi.org/10.3390/electronics10030279>.
- [37] PASZKE, A., GROSS, S., MASSA, F., LERER, A., BRADBURY, J. et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library. In: WALLACH, H., LAROCHELLE, H., BEYGEZIMER, A., ALCHÉ BUC, F. d', FOX, E. et al., ed. *Advances in Neural Information Processing Systems 32*. Curran Associates, Inc., 2019, s. 8024–8035. Dostupné z: <http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-library.pdf>.
- [38] RAMASUBRAMANIAN, B. a SELVAPERUMAL, S. A comprehensive review on various preprocessing methods in detecting diabetic retinopathy. In: *2016 International Conference on Communication and Signal Processing (ICCSP)*. IEEE, Duben 2016. DOI: 10.1109/iccsp.2016.7754220. Dostupné z: <https://doi.org/10.1109/iccsp.2016.7754220>.
- [39] REDMON, J., DIVVALA, S., GIRSHICK, R. a FARHADI, A. *You Only Look Once: Unified, Real-Time Object Detection*. arXiv, 2015. DOI: 10.48550/ARXIV.1506.02640. Dostupné z: <https://arxiv.org/abs/1506.02640>.
- [40] REN, S., HE, K., GIRSHICK, R. a SUN, J. *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. arXiv, 2015. DOI: 10.48550/ARXIV.1506.01497. Dostupné z: <https://arxiv.org/abs/1506.01497>.

- [41] RHCASILHOS, TCHOŘ, JMARCHN. *Schematic diagram of the human eye in czech* [online]. 2009 [cit. 2021-12-14]. Dostupné z: <https://commons.wikimedia.org/w/index.php?curid=7219151>.
- [42] ROZSÍVAL, P. a KUCHYNKA, P. *Oční lékařství*. 1. vyd. Praha: Grada, 2007. ISBN 978-802-4711-638.
- [43] S. HERVELLA Álvaro, ROUCO, J., NOVO, J. a ORTEGA, M. Retinal microaneurysms detection using adversarial pre-training with unlabeled multimodal images. *Information Fusion*. březen 2022, sv. 79, s. 146–161. DOI: 10.1016/j.inffus.2021.10.003. ISSN 1566-2535. Dostupné z: <https://doi.org/10.1016/j.inffus.2021.10.003>.
- [44] SANCHEZ, S. A., ROMERO, H. J. a MORALES, A. D. A review: Comparison of performance metrics of pretrained models for object detection using the TensorFlow framework. *IOP Conference Series: Materials Science and Engineering*. IOP Publishing. jun 2020, sv. 844, s. 012024. DOI: 10.1088/1757-899x/844/1/012024. Dostupné z: <https://doi.org/10.1088/1757-899x/844/1/012024>.
- [45] SANTOS, C., AGUIAR, M., WELFER, D. a BELLONI, B. A New Method Based on Deep Learning to Detect Lesions in Retinal Images using YOLOv5. In: *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. Prosinec 2021, s. 3513–3520. DOI: 10.1109/BIBM52615.2021.9669581. Dostupné z: <https://doi.org/10.1109/bibm52615.2021.9669581>.
- [46] SANTOS, C., DE AGUIAR, M. S., WELFER, D. a BELLONI, B. Deep Neural Network Model based on One-Stage Detector for Identifying Fundus Lesions. In: *2021 International Joint Conference on Neural Networks (IJCNN)*. červenec 2021, s. 1–8. DOI: 10.1109/IJCNN52387.2021.9534354. Dostupné z: <https://doi.org/10.1109/ijcnn52387.2021.9534354>.
- [47] SCHACHAT, A. P., WILKINSON, C. P., HINTON, D. R., SADDA, S. R. a WIEDEMANN, P. *Ryan's retina*. Sixth editon. Edinburgh, New York: Elsevier, 2017. ISBN 978-0-323-40198-2.
- [48] SHAHINFAR, S., MEEK, P. a FALZON, G. “How many images do I need?” Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring. *Ecological Informatics*. 2020, sv. 57, s. 101085. DOI: 10.1016/j.ecoinf.2020.101085. ISSN 1574-9541. Dostupné z: <https://doi.org/10.1016/j.ecoinf.2020.101085>.
- [49] SHEKAR, S., SATPUTE, N. a GUPTA, A. Review on diabetic retinopathy with deep learning methods. *Journal of Medical Imaging*. SPIE. 2021, sv. 8, č. 6, s. 1 – 32. DOI: 10.1117/1.JMI.8.6.060901. Dostupné z: <https://doi.org/10.1117/1.JMI.8.6.060901>.
- [50] SISODIA, D. S., NAIR, S. a KHOBRADE, P. Diabetic Retinal Fundus Images: Preprocessing and Feature Extraction For Early Detection of Diabetic Retinopathy. *Biomedical and Pharmacology Journal*. Oriental Scientific Publishing Company. červen 2017, sv. 10, č. 02, s. 615–626. DOI: 10.13005/bpj/1148. Dostupné z: <https://doi.org/10.13005/bpj/1148>.

- [51] SLÍPKA, J. a TONAR, Z. *Základy histologie*. 2. vydání. Praha: Univerzita Karlova, nakladatelství Karolinum, 2018. ISBN 978-80-246-3934-5.
- [52] VESELÝ, P. a BENEŠ, P. *Vyšetřovací metody v optometrii: a interpretace jejich výsledků v praxi*. Praha: Grada Publishing, 2019. ISBN 978-80-271-2071-0.
- [53] VISUS, SPOL. S R. O.. *Vyšetření na OCT* [online]. [cit. 2021-12-21]. Dostupné z: <https://www.ocni-visus.cz/vysetreni/vysetreni-oct/>.
- [54] WASEKAR, U. a BATHLA, R. A review on supervised learning methodologies for detection of exudates in diabetic retinopathy. *Indonesian Journal of Electrical Engineering and Computer Science*. Srpen 2021, sv. 23, s. 837. DOI: 10.11591/ijeecs.v23.i2.pp837-846. Dostupné z: <https://doi.org/10.11591/ijeecs.v23.i2.pp837-846>.
- [55] XIE, S., GIRSHICK, R., DOLLÁR, P., TU, Z. a HE, K. *Aggregated Residual Transformations for Deep Neural Networks*. arXiv, 2016. DOI: 10.48550/ARXIV.1611.05431. Dostupné z: <https://arxiv.org/abs/1611.05431>.
- [56] ZOHORA, S. E., CHAKRABORTY, S., KHAN, A. a DEY, N. Detection of exudates in diabetic retinopathy: A review. In: *2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*. IEEE, Březen 2016. DOI: 10.1109/iceeot.2016.7755052. Dostupné z: <https://doi.org/10.1109/iceeot.2016.7755052>.

Příloha A

Obsah paměťového média

- `checkpoints/`: Adresář obsahující vyučené modely.
- `docs/`: Adresář obsahující dokumentaci ke zdrojovým souborům programu.
- `Pipfile`, `Pipfile.lock`: Soubory obsahující informace o potřebných knihovnách.
- `README.md`: Popis a návod použití programu.
- `src/`: Adresář obsahující zdrojové soubory programu.
- `scripts/`: Adresář obsahující skript generující dokumentaci ke zdrojovým souborům.
- `thesis/`: Adresář obsahující zdrojový tvar písemné zprávy.
- `videos/`: Adresář obsahující videa popisující použití programu.
- `xhurta04-Detekce-patologii-na-snimcich-sitnice-oka.pdf`: Písemná zpráva.