



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH  
TECHNOLOGIÍ**

**ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION  
DEPARTMENT OF BIOMEDICAL ENGINEERING

# SEGMENTACE A MODELOVÁNÍ CÉVNÍHO STROMU VE SNÍMCÍCH SÍTNICE

BLOOD VESSEL SEGMENTATION AND MODELING IN FUNDUS IMAGES

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. JAN VÁCLAVÍK**

**VEDOUCÍ PRÁCE**

SUPERVISOR

**doc. Ing. RADIM KOLÁŘ, Ph.D.**

BRNO 2013



VYSOKÉ UČENÍ  
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

Ústav biomedicínského inženýrství

# Diplomová práce

magisterský navazující studijní obor  
Biomedicínské a ekologické inženýrství

**Student:** Bc. Jan Václavík

**ID:** 72781

**Ročník:** 2

**Akademický rok:** 2012/2013

## NÁZEV TÉMATU:

**Segmentace a modelování cévního stromu ve snímcích sítnice**

## POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte metodu detekce cévního stromu ve snímcích sítnice, která je založená na Gaborových filtrech. 2) Implementujte tuto metodu se zaměřením na hlavní cévy. 3) Prostudujte možnosti aproximace cévního stromu parabolickou, případně jinou funkcí. 4) Implementujte algoritmus, který bude automaticky aproximovat detekovaný cévní strom vybranou funkcí. 5) Výslednou metodu otestujte na definované sadě retinálních snímků a zabývejte se také robustností metody vzhledem k různému rozlišení těchto snímků. 6) Proveďte vyhodnocení metody a výsledky dostatečně diskutujte.

## DOPORUČENÁ LITERATURA:

[1] OLOUMI, F., RANGAYYAN, R.M., ELLS a A.L. Parabolic Modeling of the Major Temporal Arcade in Retinal Fundus Images. IEEE Transactions on Instrumentation and Measurement. 2012, roč. 61, č. 7, s. 1825-1838.

[2] RANGAYYAN R.M., AYRES F.J., OLOUMI F., OLOUMI F. a ESHGHZADEH-ZANJANI P. Detection of blood vessels in the retina with multiscale Gabor filters. Journal of Electronic Imaging. 2008, roč. 17, č. 2, s. 023018-023018-7.

**Termín zadání:** 11.2.2013

**Termín odevzdání:** 24.5.2013

**Vedoucí práce:** doc. Ing. Radim Kolář, Ph.D.

**Konzultanti diplomové práce:**

**prof. Ing. Ivo Provazník, Ph.D.**

*Předseda oborové rady*

## UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## **ABSTRAKT**

Studie cévního stromu v obrazech sítnice mají využití nejen na poli medicíny, ale také biometrie. Matematický popis cévního řečiště sítnice by mohl pomoci k ulehčení a vylepšení diagnóz některých chorob, k jejich automatické lokalizaci nebo k urychlení identifikace a verifikace osob. Cílem práce je navrhnout a vytvořit algoritmus, který bude automaticky aproximovat hlavní retinální cévy parabolickou, lineární a kvartickou funkcí. Hlavní část práce je tedy věnována této problematice včetně segmentace cévního řečiště pomocí Gaborových filtrů, morfologické eroze, prahování, skeletonizace, a výsledné optimalizace aproximačního modelu. Na závěr je diskutována kvalita vytvořeného modelovacího algoritmu.

## **KLÍČOVÁ SLOVA**

Obraz sítnice, segmentace cév, matematické modelování, aproximace.

## **ABSTRACT**

Studies of the vascular tree in the retina have applications not only in the medical field but also biometrics. The mathematical description of the retinal vasculature could help facilitate and improve the diagnosis of certain diseases, their automatic localization or to accelerate the identification and verification of individuals. The aim is to design and develop an algorithm that will automatically approximate major retinal vessels by parabolic, linear and kvartic functions. The main part of this thesis is therefore devoted to this issue, including vascular segmentation using Gabor filters, morphological erosion, thresholding, skeletonization and the resulting optimization of the approximation model. The quality of the produced algorithm is discussed in the summary.

## **KEYWORDS**

Retinal image, segmentation of vessels, mathematical modeling, approximation

## **BIBLIOGRAFICKÁ CITACE DIPLOMOVÉ PRÁCE**

VÁCLAVÍK, J. *Segmentace a modelování cévního stromu ve snímcích sítnice*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Ústav biomedicínského inženýrství, 2013. 65 s., 8 s. příloh. Diplomová práce. Vedoucí práce: doc. Ing. Radim Kolář, Ph.D.

## PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma Segmentace a modelování cévního stromu ve snímcích sítnice jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne 24. 05. 2013

.....

(podpis autora)

## PODĚKOVÁNÍ

Tímto bych rád poděkoval vedoucímu diplomové práce doc. Ing. Radimu Koláři, Ph.D. za jeho zájem, podporu a mnoho cenných rad při řešení a organizaci diplomové práce. Největší vděk a uznání patří mým rodičům a blízkým přátelům za jejich neustálou podporu a trpělivost během celého studia.

V Brně dne 24. 05. 2013

.....

(podpis autora)

# OBSAH

<b>Seznam obrázků</b>	<b>viii</b>
<b>Seznam tabulek</b>	<b>xi</b>
<b>Úvod</b>	<b>1</b>
<b>1 Sítnice</b>	<b>2</b>
1.1 Anatomie a fyziologie sítnice .....	3
1.2 Topografie sítnice .....	4
1.3 Oftalmoskopie.....	4
1.3.1 Přímá oftalmoskopie .....	5
1.3.2 Nepřímá oftalmoskopie.....	6
1.4 Fundus kamera.....	7
1.4.1 Technický popis .....	7
1.5 Další metody oftalmoskopie .....	8
<b>2 Soubory testovacích dat</b>	<b>9</b>
2.1 Zdraví jedinci.....	9
2.2 Nemocní jedinci.....	11
<b>3 Modelovací Algoritmus</b>	<b>12</b>
3.1 Vstup dat .....	13
3.2 Předzpracování.....	13
3.2.1 Modifikace vstupního snímku .....	13
3.2.2 Redukce vstupního snímku .....	13
3.2.3 Luminiscenční komponenta .....	14
3.3 Segmentace cévního řečiště .....	16
3.3.1 Gaborova filtrace .....	16

3.3.2	Morfologické operace .....	23
3.3.3	Prahování .....	25
3.3.4	Skeletonizace .....	27
3.4	Úprava binárních snímků .....	29
3.5	Aproximace a modelování .....	31
3.5.1	Aproximace vrcholu .....	31
3.5.2	Aproximace matematickou funkcí .....	33
3.5.3	Modelování cévního oblouku .....	35
3.6	Export a zobrazení výsledků .....	37
<b>4</b>	<b>Zpracování výsledků</b>	<b>39</b>
4.1	Přesnost modelovacího algoritmu .....	39
4.1.1	Statické souřadnice vrcholu aproximační funkce .....	40
4.1.2	Dynamické souřadnice vrcholu aproximační funkce .....	47
4.1.3	Celkové zhodnocení kvality přesnosti .....	56
4.2	Robustnost modelovacího algoritmu .....	57
4.3	Celkové zhodnocení modelovacího algoritmu .....	59
	<b>Závěr</b>	<b>61</b>
	<b>Literatura</b>	<b>63</b>
	<b>Seznam příloh</b>	<b>65</b>

# SEZNAM OBRÁZKŮ

Obr. 1: Anatomie lidského oka [8] .....	2
Obr. 2: Vrstvy sítnice [17] .....	3
Obr. 3: Charakteristiky sítnice .....	4
Obr. 4: Přímá oftalmoskopie [18] .....	5
Obr. 5: Nepřímá oftalmoskopie [19] .....	6
Obr. 6: Optický systém fundus kamery [8] .....	8
Obr. 7: Vzorok levého a pravého oka .....	10
Obr. 8: Vzorok levého a pravého oka různá kvalita .....	10
Obr. 9: Vzorok levé a pravé oko nemocní jedinci .....	11
Obr. 10: Schéma modelovacího algoritmu .....	12
Obr. 11: Redukce vstupního snímku .....	14
Obr. 12: Lumiscenční komponenty .....	15
Obr. 13: Výsledná Luminiscenční komponenta .....	15
Obr. 14: Vstup a výstup segmentace modelovacího algoritmu .....	16
Obr. 15: Jádra Gaborova filtru o velikosti 10x10 .....	17
Obr. 16: Vady po Gaborově filtraci .....	18
Obr. 17: Jádra Gaborových filtrů - 3D .....	19
Obr. 18 :Gaborova filtrace sítnice .....	20
Obr. 19: Kombinační metody .....	21
Obr. 20: Kombinace orientovaných Gaborových filtrů .....	22
Obr. 21: Výsledky obrazů před a po Gaborově filtraci .....	22
Obr. 22: Binární dilatace .....	23
Obr. 23: Binární eroze .....	24
Obr. 24: Erozní maska .....	24

Obr. 25: Histogram s vyznačeným prahem .....	26
Obr. 26: Prahování s různými hodnotami prahu .....	27
Obr. 27: Metoda střední osy .....	28
Obr. 28: Sekvenční ztenčování [20] .....	28
Obr. 29: Skeletonizace cévního řečiště .....	29
Obr. 30: Finální úpravy binárních snímků sítnice .....	30
Obr. 31: Koncový výsledek zpracování testovacího obrazu .....	30
Obr. 32: Hlavní cévní oblouk [1] .....	31
Obr. 33: Různé výsledky aproximace vrcholu .....	32
Obr. 34: Procentuální úspěšnosti aproximace vrcholu .....	33
Obr. 35: Parabolická aproximační funkce [16] .....	33
Obr. 36: Lineární aproximační funkce .....	34
Obr. 37: Kvartická aproximační funkce .....	34
Obr. 38: Modelování parabolou .....	36
Obr. 39: Duální modelování .....	36
Obr. 40: Výsledky sekcí modelovacího algoritmu .....	38
Obr. 41: Rozložení absolutní chyby na celém spektru testovacích dat .....	40
Obr. 42: Procentuální vyhodnocení kvality přesnosti .....	41
Obr. 43: Rozložení absolutní chyby na celém spektru testovacích dat .....	41
Obr. 44: Procentuální vyhodnocení kvality přesnosti .....	42
Obr. 45: Rozložení absolutní chyby na celém spektru testovacích dat .....	43
Obr. 46: Procentuální vyhodnocení kvality přesnosti .....	44
Obr. 47: Rozložení absolutní chyby na celém spektru testovacích dat .....	45
Obr. 48: Procentuální vyhodnocení kvality přesnosti .....	46
Obr. 49: Rozložení absolutní chyby na celém spektru testovacích dat .....	47
Obr. 50: Procentuální vyhodnocení kvality přesnosti .....	47
Obr. 51: Rozložení absolutní chyby na celém spektru testovacích dat .....	48
Obr. 52: Procentuální vyhodnocení kvality přesnosti .....	48

Obr. 53: Rozložení absolutní chyby na celém spektru testovacích dat .....	49
Obr. 54: Procentuální vyhodnocení kvality přesnosti.....	49
Obr. 55: Rozložení absolutní chyby na celém spektru testovacích dat .....	50
Obr. 56: Procentuální vyhodnocení kvality přesnosti.....	51
Obr. 57: Rozložení absolutní chyby na celém spektru testovacích dat .....	52
Obr. 58: Procentuální vyhodnocení kvality přesnosti.....	53
Obr. 59: Rozložení absolutní chyby na celém spektru testovacích dat .....	54
Obr. 60:Procentuální vyhodnocení kvality přesnosti.....	55
Obr. 61: Nekorektní výsledný model.....	59

# SEZNAM TABULEK

Tab. 1: Souhrn kvality přesnosti modelovacího algoritmu.....	56
Tab. 2: Robustnost modelovacího algoritmu - zdravé oči .....	58
Tab. 3: Robustnost modelovacího algoritmu - nemocné oči .....	58

# ÚVOD

Zrak je pro člověka nejdůležitějším smyslem, s jehož pomocí přijímá skoro 80% všech okolních informací. Sítnice je nervová tkáň oka, která má na starosti přijímání a zpracování všech zrakových vjemů. Z těchto důvodů je velmi důležité umět tuto strukturu pochopit, vyšetřit, zmapovat, modelovat a operovat. Hlavní důvody jsou prevence proti chorobám, ulehčení jejich diagnózy a léčby nebo odstranění zrakových genetických vad.

V dnešní době je vyšetření očního pozadí neboli oftalmoskopie běžnou vyšetřovací metodou očního lékařství. Založil ji německý fyzik Hermann Ludwig Ferdinand von Helmholtz začátkem druhé poloviny 19. století. Princip oftalmoskopu se téměř v nezměněné formě používá dodnes. Používají se sice jiné materiály a zdroje světla, ale princip osvětlení očního pozadí a pozorování jeho odrazu je zachován.

S příchodem počítačových a informačních systémů se zlepšuje jak kvalita, tak přesnost očního vyšetření. Mimo jiné s digitalizací a archivací snímků přichází možnost podrobnějšího pozorování a studování charakteristik očního pozadí. Přichází tedy na řadu zpracování a modelování obrazů, jehož cílem je jednotlivé charakteristiky vyzdvihnout a matematicky je popsat. V závislosti na nemoci se mění šířka nebo zakřivení jednotlivých cév, tvar cévního řečiště nebo složení vrstvy sítnice. Ze změn jednotlivých charakteristik se dají určit různé patologie jako tvrdnutí tepen, zvýšený tlak, cukrovka nebo krátkozrakost.

Dalším využitím modelování cévního řečiště by mohlo být v biometrii při rozlišování jednotlivých osob. Tato myšlenka je založena na mapování cévního stromu očního pozadí. Předpokladem je, stejně jako u otisku prstů, že neexistují žádní dva jedinci, kteří by měli stejné rozvětvení očních cév.


Na téma segmentace a modelování různých charakteristik očního pozadí se vytvořilo mnoho studií. Tato studie se zabývá vytvořením modelovacího algoritmu, který by automaticky modeloval za použití Gaborových filtrů a různých segmentačních a morfologických metod tzv. hlavní cévní oblouk.

V práci je vysvětlen princip získávání obrazů oční sítnice různými metodami, a jaké jsou jejich vlastnosti. Druhá část je zaměřena na vysvětlení principu hlavních metod zpracování obrazu a jejich využití pro vytvářený algoritmus. Třetí část se zabývá vlastní procedurou vytváření matematického modelu, jejími vlastnostmi a nastavením. Poslední sekce vyhodnocuje kvality vytvořeného algoritmu.

# 1 SÍTNICE

Oko na Obr. 1, je párový smyslový orgán reagující na světlo zajišťující zrak. Má tvar nedokonalé koule o průměru cca 24 mm a je uloženo v lebeční jamce v tukovém polštáři, chráněné kostmi očníce, očním víčkem a řasami. Pohyb je zajištěn šesti okohybnými svaly, čtyři umožňující přímý a dva šikmý pohyb. Díky tomu je oko nejpohyblivějším orgánem lidského těla.

Principem oka je přijímání světelných podnětů a jejich přeměna na nervové elektrické impulsy vedoucí do mozku. Regulaci vstupního světla má provádět duhovka obsahující svalová vlákna umožňující stažení či roztažení zornice. Aby nedocházelo k rozptylu světla, jsou všechny části oka, kterými paprsek prochází, průhledné. Rohovka s čočkou umožňují spojení a zaostření světelného paprsku na sítnici. Pozorovaný objekt je na sítnici promítnut převráceně. Světlo dopadající na sítnici způsobuje chemické přeměny ve světločivných buňkách, vznikají elektrické impulsy, které jsou optickým nervem vedeny do mozku. Největší oblast oka je vyplněna sklivcem, který udržuje v oku stálý tlak a tím i tvar.

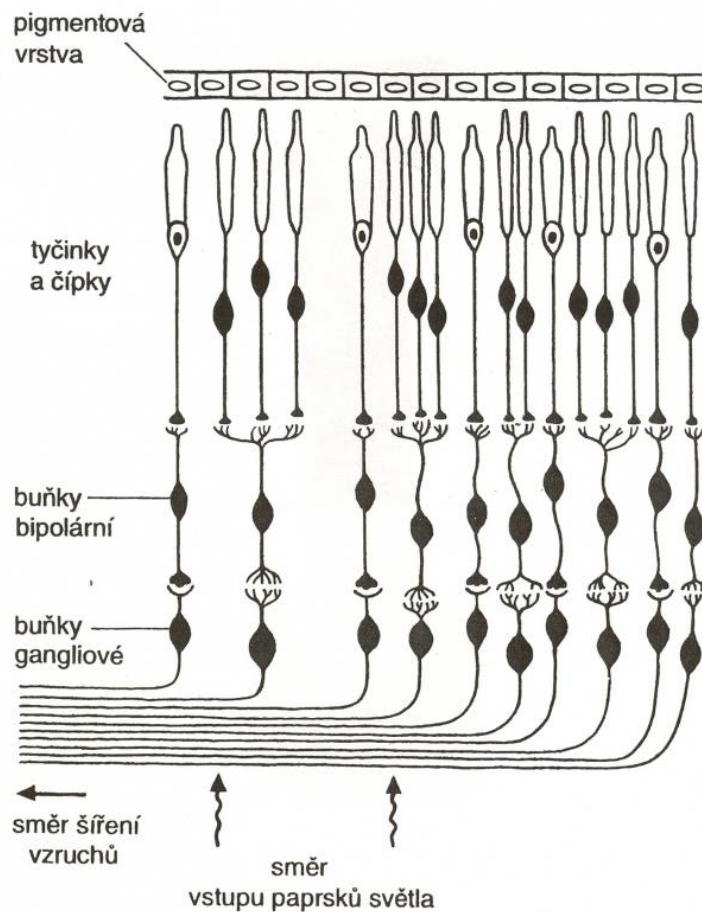


Obr. 1: Anatomie lidského oka [8]

## 1.1 Anatomie a fyziologie sítnice

Sítnice je jemná vícevrstevná blána, viz Obr. 2, silná mezi 0,2-0,4 mm tvořící nejvnitřnější list oční koule. Zevní vrstva obsahuje pigmentový epitel, který pohlcuje již zaznamenané světelné paprsky, zabraňuje tím jejich odrazu, a zvyšuje tak ostrost vidění.

Vnitřní vrstva není homogenní a obsahuje 5 druhů nervových buněk rozložených ve třech vrstvách. Vnější nukleární vrstva obsahuje světločivné buňky v podobě tyčinek a čípků. Tyčinky, kterých je přibližně 120 miliónů, slouží k vnímání kontrastů a čípky, v počtu přibližně 6 miliónů, umožňují barevné vidění. Vnitřní nukleární vrstva se skládá z bipolárních, horizontálních a amakriálních buněk, propojujících světločivné gangliové a bipolární buňky. Vrstva gangliových buněk, kterých je přibližně desetkrát méně než světločivných, sbírá informace z tyčinek a čípků a přeposílá je do mozku.

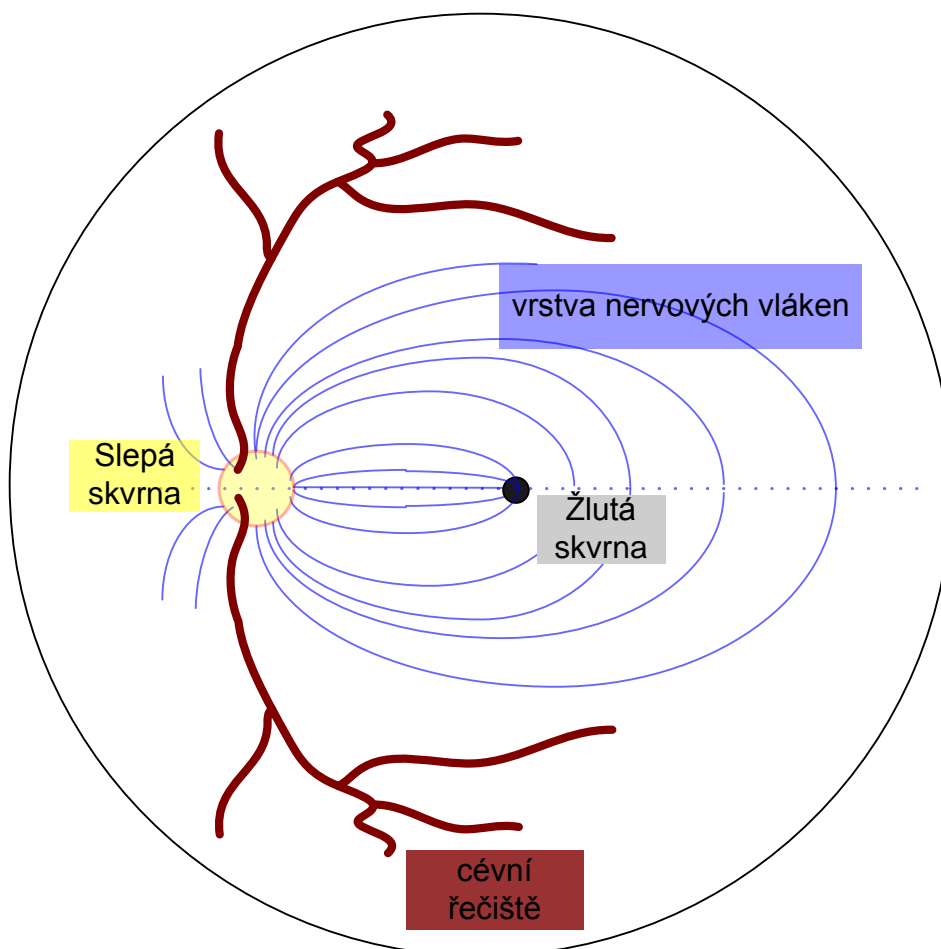


Obr. 2: Vrstvy sítnice [17]

## 1.2 Topografie sítnice

Oční pozadí popisují tři hlavní útvary: slepá skvrna, žlutá skvrna a cévní řečiště, viz Obr. 3. Slepá skvrna neboli optický disk, je místo, ve kterém vystupuje zrakový nerv a vstupuje arteria centralis retinae, neboli cévnatka, tepna zásobující krví sítnici oka. Arteria centralis retinae se poté dělí na 4 hlavní větve. Žlutá skvrna je místem maximální ostrosti zraku, vrstva sítnice zde obsahuje pouze čípky.

Dalším faktorem je RPE, neboli sítnicový pigmentový epitel. Jedná se o zbarvení sítnice, závislé obecně na stupni pigmentace daného jedince.



Obr. 3: Charakteristiky sítnice

## 1.3 Oftalmoskopie

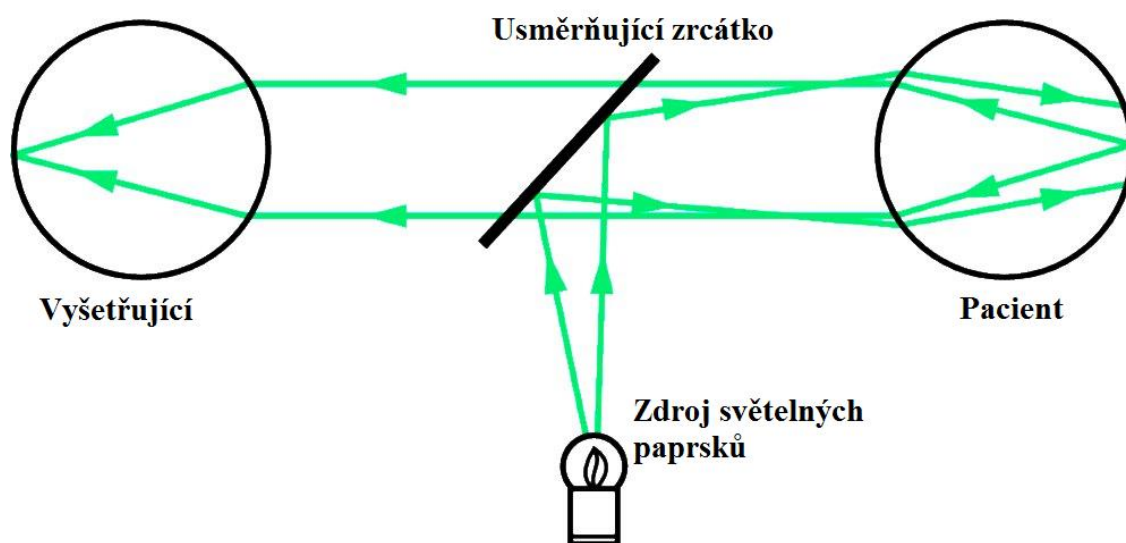
Vyšetřovací metoda umožňující vyšetření zadního segmentu oka, tedy sklivce a především sítnice a terče zrakového nervu. Využívá se dostatečně intenzivního

světelného paprsku, který vniká do oka a umožňuje pozorovat pomocí odražených paprsků změny na charakteristických útvarech sítnice. Důležitou podmínkou správného zobrazení je, pokud osa osvětlovacích paprsků je téměř shodná s odraženými pozorovacími paprsky. Výhodou oftalmoskopie jsou finanční nenáročnost, kompaktnost a dostupnost používaných přístrojů. Základem koncepce je Helmholtzovo zrcátko. Podle způsobu a metody provedení vyšetření se dělí na přímou a nepřímou oftalmoskopii.

### 1.3.1 Přímá oftalmoskopie

Přímá oftalmoskopie je dosud nejjednodušší a zároveň nejpoužívanější technologie vyšetření očního pozadí. Hlavní výhodou této metody je získání přímého obraz očního pozadí, až 16-ti násobné zvětšení a možnost vyšetření sítnice bez rozšíření zornice. Velkou nevýhodou je velmi úzké zorné pole pohybující se přibližně mezi  $8^\circ$  až  $10^\circ$  očního pozadí, špatná viditelnost sítnice při různých zákalech, pouze dvojrozměrný obraz, a často z hygienických důvodů nevhodná krátká obsluhovací vzdálenost přibližně 2cm.

K vyšetření touto metodou se používá oftalmoskop. Jedná o ruční nástroj se zabudovaným osvětlením. Základem je správné protisměrné postavení vyšetřujícího lékaře a pacienta, viz Obr. 4 tak, že se na sítnici lékaře reflektuje osvětlená plocha pacientovy sítnice. Do oka vyšetřovaného tedy vstupují divergentní paprsky, jež se lámou na optickém prostředí jeho oka. Pozorovatel pak může detailněji zkoumat menší plochu očního pozadí pacienta, avšak dostatečně zvětšenou přes použité korekční členy. [9]

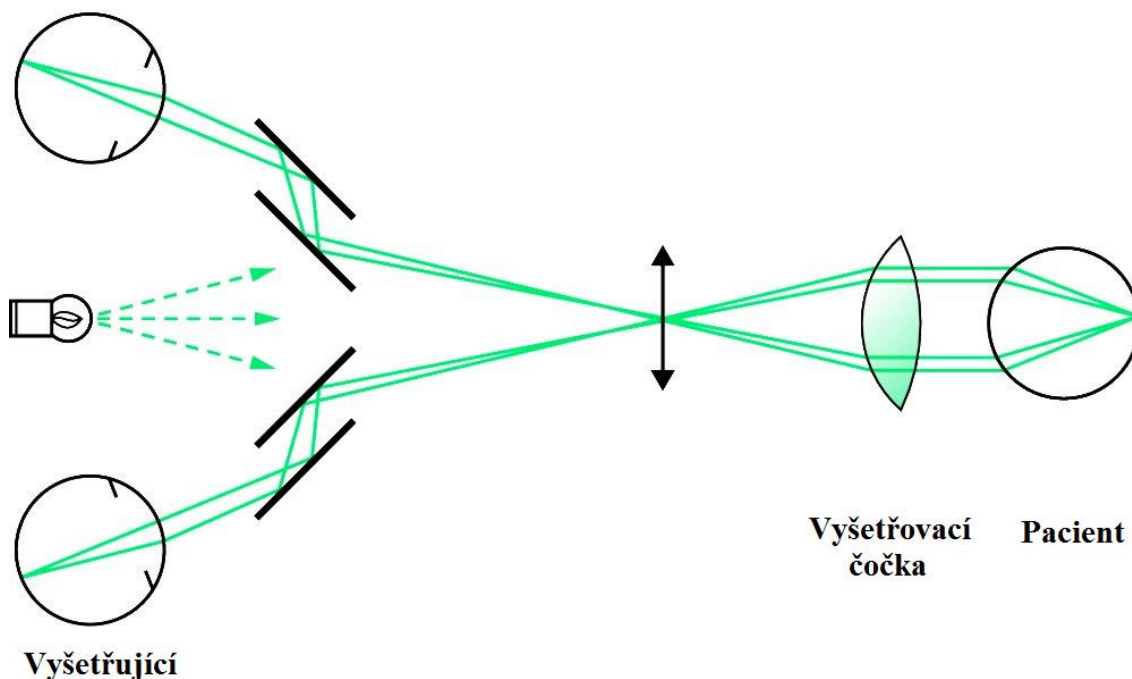


Obr. 4: Přímá oftalmoskopie [18]

### 1.3.2 Nepřímá oftalmoskopie

Nepřímý oftalmoskop, viz Obr. 5, se skládá ze světelného zdroje a pozorovacího systému. Využívá vyšetřovací čočku, která má nejčastěji tvar asférické spojky. Přes tuto čočku se osvětluje zadní segment a zároveň se pozoruje obraz sítnice. Používají se čočky různé optické mohutnosti od 15 do 30 D. Opticky mohutnější čočka poskytuje menší obraz a širší zorné pole. Vzdálenost čočky od pacienta musí odpovídat její ohniskové vzdálenosti. Obraz sítnice je přes čočku zobrazen jako reálný, ale převrácený. [9]

Nevýhodou této metody je delší trénink vyšetřujícího lékaře způsobený převráceným obrazem. Nepřímá oftalmoskopie umožňuje menší zvětšení (max. 5,5 krát) než u přímé. Zorný úhel je díky spojce širší než u přímé metody přibližně o 35°a více. Je tak zobrazena prostorově větší část sítnice. Dále umožňuje stereoskopický obraz, díky pozorování oběma očima. Hlavní výhodou nepřímých oftalmoskopů je možnost využití různých barevných filtrů umožňujících lepší zobrazení různých charakteristik sítnice. [9]



Obr. 5: Nepřímá oftalmoskopie [19]

## 1.4 Fundus kamera

Fundus kamera je speciální oftalmologický přístroj postavený na obdobném zobrazovacím principu jako nepřímá oftalmoskopie. Umožňuje zobrazení očního pozadí formou fotografického, digitálního 2D případně i 3D obrazu. Skládá se z nízko-energetického mikroskopu a fotoaparátu. Součástí výsledného obrazu je snímek centrální krajiny, disku optického nervu a okolní retinální tkáně včetně cév.


### 1.4.1 Technický popis

Mechanismus fundus kamery se dělí na tři základní části: mechanickou, optickou a elektrickou. Hlavní součástí mechanického systému je nastavení polohy kamery tedy výška a směr. Toto nastavení se provádí u starších přístrojů manuálně, u novějších elektronicky. V obou případech závisí nastavení na operátorovi. Optická část má zajišťuje přenos a úpravu vysílaných a odražených světelných paprskových svazků. Elektrický subsystém obstarává zdroj světla a energii pro ostatní komponenty fundus kamery. [9]

Základem získání snímku očního pozadí je pozorování v červeném reflexu, viz Obr. 6. Fundus je nutno osvětlit paprsky bílého světla. Světlo vycházející ze zdroje se odráží od zrcadla, dále prochází přes kotouč s červeným, modrým, zeleným filtrem a otvorem pro průchod nefiltrovaného světla. Paprsky následně prochází soustavou šikmých zrcadel a optických členů, které je soustředí na zrcadlovou plochu aperturního charakteru s centrálním otvorem. Tyto paprsky musí dopadat mimo zmíněný otvor, který slouží pro odražené paprsky přicházející z vyšetřovaného oka. Na reflexní ploše se paprsky odráží a přes objektiv opouští výstupní pupilou přístroj v podobě tzv. doughnut beams (iluminační paprsky v podobě jakési koblihy). Osvětlovací paprsky se po dopadu na sítnici odráží, a vstupují středem koblihového tvaru osvětlovací složky do objektivu. Poté naráží znovu na aperturní reflexní plochu, jejímž středovým otvorem prochází dále přes soustavu kondenzačních a korekčních členů do okuláru, nebo jsou pomocí detektorů převáděny na elektrický signál a dále zpracovávány na výsledný obraz. Ve výsledku vznikne vzpřímený a několikrát zvětšený obraz očního pozadí. Zvětšení závisí na rozsahu zorného vyšetřovaného pole. Ten se pohybuje u jednotlivých modelů podle požadovaného nastavení v rozmezí od 15° při současném zvětšení 5x až 140°, kdy je obraz poloviční. Nejběžnější je zvětšení 2,5x, kdy přístroj zobrazuje zorné pole o rozsahu od 30° do 50°. [9]

Pokud je třeba zvýraznit pouze některé struktury neuroretiny, lze předřadit do chodu světelných paprsků barevné filtry. Jedná se o červený (640 nm), zelený

(540 nm) a modrý filtr (450 nm). Některé přístroje rozšiřují nabídku ještě např. o filtr žlutý (560 nm), nebo kombinaci zeleného a modrého (490 nm), jinak se používá bílé světlo bez filtrů. [9]



Obr. 6: Optický systém fundus kamery [8]

## 1.5 Další metody oftalmoskopie

- Oční ultrazvukové vyšetření
- SLO – Scanning Laser Ophthalmoscopy – laserová skenovací oftalmoskopie
- HRT – Heidelberg Retina Tomography – laserové konfokální oftalmoskopie
- OCT – Optical Coherence Tomography – optická koherentní tomografie
- GDx – Nerve Fiber Analyzer – analýza vrstvy nervových vláken využívající dvojlom nervových vláken
- RTA – Retinal Thickness Analyzer - dynamická analýza cévního řečiště na sítnici

## 2 SOUBORY TESTOVACÍCH DAT

Hlavní součástí této práce je sada retinálních snímků. Na základě jejich charakteristik bude vytvářen modelovací algoritmus cévního stromu. Obrazy jsou rozděleny podle zdravotního stavu oka do dvou testovacích skupin na zdravé a nemocné jedince.

Snímky byly pořízeny pomocí těchto fundus kamer:

**Zdraví – Canon CR1 + digitální fotoaparát Canon EOS D40, zorné pole 60°**


**Nemocní – CF-60UDi + digitální fotoaparát Canon EOS D20, zorné pole 45°**

### 2.1 Zdraví jedinci


Snímky byly získány od 28 zdravých dobrovolníků různého věku a pohlaví. U každého byly vyfoceny dva obrazy levého a dva obrazy pravého oka, viz Obr. 7 a 8. Celkem je k dispozici 112 specifických testovacích snímků.

Jedná se o barevné obrázky ve formátu JPEG, což je standardní metoda ztrátové komprese pro ukládání digitálních obrázků. Každý obrázek dosahuje velikosti 3888 na 2592 pixelů a úroveň obrazového bodu je 24 BPP, neboli umožňuje  $2^{24}$  různých barev. Přičemž značná část obrázku je pokryta černým pozadím. JPEG nepatří v důsledku komprese mezi nejkvalitnější formáty, ale díky velkému rozlišení testovacích obrázků není nedostatek kvality pro funkci algoritmu výrazný.

Důležitým faktorem pro vytváření modelovacího algoritmu je sada vždy alespoň dvou snímků stejného oka u každého jedince. Důležitost spočívá ve schopnosti ověřit robustnost vytvořeného modelovacího algoritmu. Tyto párové snímky se od sebe liší převážně úrovní jasu a částečně i lehkým posuvem či rotací. Někdy bývají tyto rozdíly subjektivně nepatrné, jindy velmi výrazné, viz Obr. 7 a 8.



Obr. 7: Vzorok levého a pravého oka




Obr. 8: Vzorok levého a pravého oka různá kvalita

## 2.2 Nemocní jedinci

Sada 22 snímků získaných od 13 pacientů trpících diabetickou retinopatií se skládá z 12 pravých a 10 levých očí. Opět jsou ve formátu JPEG s velikostí 1500 na 1000 pixelů při 24 BPP. Oproti obrázkům zdravých jedinců, neobsahují snímky nemocných pacientů celou plochu sítnice, viz Obr. 9.

Diabetická retinopatie (DR) je specifická oční komplikace cukrovky. DR je nejčastějším vaskulárním onemocněním sítnice. Udává se, že tato nemoc se objevuje nejčastěji po více než deseti letech trvání cukrovky, ale vyskytují se i výjimky. Čím lépe je diabetes v jeho průběhu kompenzován, tím oční komplikace nastupují později. Téměř 2% všech diabetiků kvůli retinopatii oslepnou. DR představuje závažný zdravotně-sociální problém. DR v sítnici způsobuje změny ve struktuře a ve funkci cévní stěny kapilár, ztlustění bazální membrány, oslabení kapilární stěny, porušení permeability stěn kapilár a jiné vady. Některé z nich mají příznaky, které je možno rozeznat i z retinálních snímků jako například mikroaneuryzmata, vatovitá ložiska, tvrdé exudáty, žilní abnormality aj. [13]



Obr. 9: Vzorky levé a pravé oko nemocní jedinci

### 3 MODELOVACÍ ALGORITMUS



Obr. 10: Schéma modelovacího algoritmu

Modelovací algoritmus této diplomové práce se skládá z pěti hlavních částí, viz Obr. 10. Program byl vytvořen v programovém prostředí MATLAB. Hlavní funkcí programu je načíst obraz sítě, provést úpravu a aproximovat vhodný model cévního stromu. Program byl tvořen s důrazem na dostatečnou robustnost a schopnost vytvořit model pro jakýkoliv snímek sítě nezávisle na kvalitě vstupního obrazu.

## **3.1 Vstup dat**

Z důvodu velkého množství testovacích obrazových dat, viz Kap. 2, bylo zapotřebí vytvořit skript umožňující jejich automatické načítání. Problematika byla řešena za pomoci práce se strukturami. V této části se manuálně volí pouze soubor dat určený pro testování.

## **3.2 Předzpracování**

Tento segment je rozložen do několika podfunkcí. Skládá se z modifikace různých typů obrazů, redukce obrazové informace, určení luminiscenční komponenty a morfologické binární eroze.

### **3.2.1 Modifikace vstupního snímku**


Z důvodu různých vstupních obrazů, viz Kap. 2, nastává nutnost jejich parametry (velikost, zorný úhel) modifikovat na stejnou úroveň, umožňující zbytku programu pracovat pouze s jedním nastavením. Tímto se zabývá první funkce předzpracování. Z důvodu limitu dvou sad vstupních informací, nebyla nutnost tuto funkci rozšiřovat na jakékoliv parametry obrazů a je omezena pouze na dva typy obrazů, které byly k dispozici.

### **3.2.2 Redukce vstupního snímku**

Nevýhodou testovacích vstupních dat je velké množství nepotřebné obrazové informace, které zvyšuje náročnost programových operací. Jedná se o černé pozadí, které omezuje zorné pole scény. Z tohoto důvodu je z obrazu vyjmuta jen část s informacemi o sítnici, viz Obr. 11. Druhým krokem je podvzorkování na 1/4 velikosti obrazové informace. Podvzorkování je provedeno funkcí systému MATLAB „imresize“. Funkce využívá bikubické interpolace s použitím antialiasingového filtru. Tato úprava se jeví jako ideální, zachovává stále velké množství potřebných dat, přesto snižuje výpočetní náročnost. Nastane redukce obrazu z velikosti 3888 x 2592 na konečných 1267x1251pixelů.

Před redukcí 3888 x 2592

Po redukcí 1267x1251



Obr. 11: Redukce vstupního snímku

### 3.2.3 Luminiscenční komponenta

Luminiscenční, neboli jasová složka  $Y$  vychází z barevného modelu YUV (3.1), kde  $U$  a  $V$  jsou barevné složky. Jasová složka nabývá hodnot v rozsahu od 0 (černá) do 1 (bílá). Princip jasové složky je založen na vytvoření šedo-tónového obrazu složením jednotlivých vrstev RGB v určitém poměru (3.2). Poměr určují zvolené koeficienty  $k_{xy}$ .

$$\begin{pmatrix} Y \\ U \\ V \end{pmatrix} = \begin{pmatrix} k_{11} & k_{12} & k_{13} \\ k_{21} & k_{22} & k_{23} \\ k_{31} & k_{32} & k_{33} \end{pmatrix} \times \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (3.1)$$


$$Y = k_{11} \times R + k_{12} \times G + k_{13} \times B \quad (3.2)$$

Důvodem použití této komponenty je snaha o zvýraznění cév a co nejvíce potlačit pozadí a ostatní struktury před segmentací.

Červená složka převážně dosahuje světlých výsledků, ve kterých je informace o krevním řečišti mírně potlačena. V modré složce dochází k částečné ztrátě potřebné obrazové informace, obrazy jsou převážně velmi tmavého charakteru. V modré složce je přítomen výrazný šum, který může detekci cév ovlivnit. Zelená vrstva nejlépe zobrazuje cévy a tepny a neobsahuje tak výrazný škodlivý šum oproti modré vrstvě. Na Obr. 12. jsou zobrazeny komponenty koeficienty: RGB 1R1G1B, červená 1R0G0B, zelená 0R1G0B a modrá 0R0G1B. Provedlo se několik dalších kombinací a bylo zjištěno, že kombinace zelené a modré dosahuje také dobrých výsledků.

Nicméně na základě konzultace s vedoucím práce a předešlé studie (Parabolic Modeling of the Major Temporal Arcade in Retinal Fundus image) byla zvolena jasová složka s formátem, viz (3.3), Obr.13.[1]

$$Y = 0,299 \times R + 0,587 \times G + 0,114 \times B \quad (3.3)$$



Obr. 12: Lumiscenční komponenty




Obr. 13: Výsledná Luminiscenční komponenta

### 3.3 Segmentace cévního řečiště

Segmentace digitálních obrazů je jedním z nejvýznamnějších souborů metod analýzy obsahu zpracovávaných dat. Podstata spočívá v automatickém rozčlenění snímku do oblastí, které mají stejné vlastnosti nebo souvislost s oblastmi reálného světa zachyceného v obraze. Výsledky segmentace se rozlišují na komplexní a částečnou segmentaci. Komplexní segmenty plně korespondují s objekty vstupního obrazu, částečné nemusí plně odpovídat objektům obrazu. Jedním z hlavních problémů ovlivňujících segmentaci je nejednoznačnost obrazových dat, často doprovázená informačním šumem.

Cílem této sekce modelovacího algoritmu není pouze segmentace, ale celková úprava obrazu pro následnou modelaci cévního řečiště, viz Obr. 14. Primární nároky jsou kladeny na co nejlepší, ale zároveň nejrobustnější sadu metod vedoucích k separaci hlavních cév oční sítnice od ostatních objektů obrazu. Hlavní metody použité v této segmentaci jsou Gaborova filtrace, morfologická eroze, prahování a skeletonizace. Všechny jsou navrhovány tak, aby dosahovali co možná nejlepších výsledků pro co možná nejširší škálu testovacích obrazů.



Obr. 14: Vstup a výstup segmentace modelovacího algoritmu

#### 3.3.1 Gaborova filtrace

Gaborova funkce je sinusově modulovaná Gaussova funkce. Princip Gaborovy


filtrace je postaven na podobnosti zpracování informace v raných stádiích procesu vnímání některých savců. Filtr byl vytvořen jako model, který co nejdříve kopíruje funkci neuronů v centru zraku. Pro své vlastnosti je vhodný pro, extrakci charakteristických rysů, texturové segmentace, analýzy a korektury, kódování obrazu, detekci hran, počítačové vidění aj. [2], [5]

Jeho využitím na poli detekce cévního řečiště sítnice, se díky jeho vlastnostem, zabývalo již několik studií. Používají se jeho úhelně orientované 2D formy. Pro tuto práci bylo vybráno tzv. jádro Gaborova filtru o formulaci:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{(x\cos\theta + y\sin\theta)^2}{\sigma_x^2} + \frac{(-x\sin\theta + y\cos\theta)^2}{\sigma_y^2}\right)\right] \cos(2\pi f_0 x) \quad (3.4)$$

kde  $\sigma_x$  a  $\sigma_y$  jsou směrodatné odchylky Gaussovské obálky vzhledem k ose  $x$ , respektive  $y$ ,  $f_0$  je prostorová frekvence a  $\theta$  je orientace filtru.[2]

Obrazový výstup po aplikaci filtru na obraz sítnice závisí na umístění jádra filtru v každém vzorkovacím bodě obrazu. Pro každý vzorkovací bod lze získat  $n$  výstupů v závislosti na orientaci filtru  $\theta$ . Velikost a tvar jádra určují směrodatné odchylky  $\sigma_x$ ,  $\sigma_y$  a frekvence  $f_0$ .




Obr. 15: Jádra Gaborova filtru o velikosti 10x10

Cílem je detekovat především hlavní silné cévy, které vycházejí z optického disku pod úhlem přibližně 45, resp. 135° a místy se stáčí k 0 nebo 90°. Úhel  $\theta$  je nastaven

na hodnoty  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , a  $135^\circ$ . Pro detailnější filtraci by bylo zapotřebí vzít širší vzorek orientačních úhlů. Parametry  $\sigma_x$ ,  $\sigma_y$  a  $f_0$  musí být nastaveny podle velikosti detekovaných cév, které závisí na detailu a rozlišení snímku cévního řečiště. Velikost hlavních cév tohoto modelu odpovídá cca 15 pixelů.

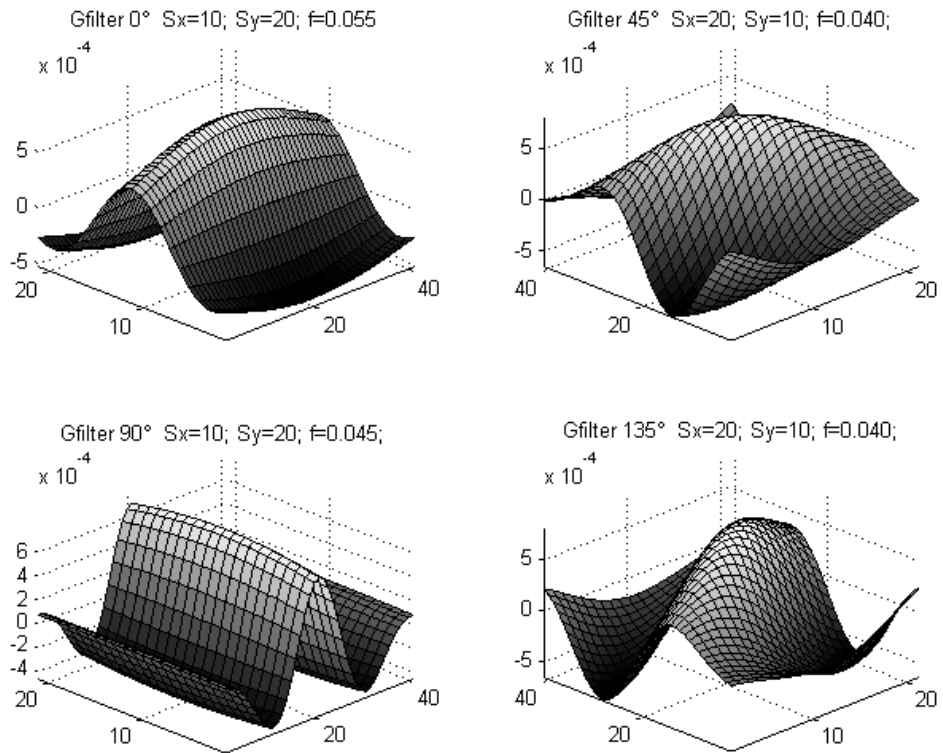
V případě špatného zvolení parametrů, filtrace vykazuje vady detekce cévního řečiště, viz Obr. 16. V první řadě se použití filtru vůbec neprojeví, nebo se potlačí cévy, které splynou s pozadím. Další problematická varianta vzniká, když je zvýrazněno malé množství cév. Jiná situace nastane, když jsou detekovány hrany cév a nikoliv jejich střed. V neposlední řadě vzniká v obraze celoplošný škodlivý šum nebo je snímek velmi rozmazaný.




Obr. 16: Vady po Gaborově filtraci

K nalezení optimálního nastavení jednotlivých parametrů byl napsán skript,

který prováděl Gaborovu filtraci snímků s proměnným nastavením parametrů, viz Obr. 18. Analýzou a následnou konzultací s vedoucím práce bylo zvoleno nastavení parametrů jader pro jednotlivé orientační úhly, viz Obr 17.



Obr. 17: Jádra Gaborových filtrů - 3D




Obr. 18 :Gaborova filtrace sítnice


Po každé filtraci vzniknou 4 kopie vstupního obrazu, odpovídající jednotlivým úhlově orientovaným filtrům. Pro dosažení pouze jednoho výstupního snímku se provede jejich kombinace. Při hledání nejlepšího způsobu kombinace bylo vyzkoušeno několik různých matematických metod jako střední hodnota, minimum a maximum, viz Obr. 19. Maximum, na základě charakteristik jednotlivých výsledků, vykazuje nejlepší vlastnosti pro následné zpracování. Obsahuje nejmenší šum a prokazuje nejvíce zvýrazněné hlavní cévy. Maximum odpovídá i teoretickému předpokladu, kdy se očekává velká odezva filtru v místě, kde se konvoluční jádro shoduje s tvarem cév.

MAX

Střední hodnota




MIN



Obr. 19: Kombinační metody


Spojení je vytvořeno uložení vždy maximální, minimální nebo střední hodnoty určeného pixelu ze všech kopií, viz Obr. 20. Dosáhne se zvýraznění hlavních cév ve všech směrech.




Obr. 20: Kombinace orientovaných Gaborových filtrů

Výsledné nastavení parametrů je natolik robustní, že u všech testovacích dat, po průchodu nastaveným Gaborovým filtrem, byly zvýrazněny hlavní cévy a potlačeno pozadí, viz Obr. 21. Nicméně nejlepších výsledků je možno dosáhnout specifickým nastavením směrodatných odchylek  $\sigma_x$ ,  $\sigma_y$  a frekvence  $f_0$  pro jednotlivé obrazy.

## Předzpracování



## Gaborova filtrace



Obr. 21: Výsledky obrazů před a po Gaborově filtraci

### 3.3.2 Morfologické operace

Morfologii lze chápat jako prostředek při digitálním zpracování obrazu, který zpočátku sloužil jen k úpravě binárních obrazů. V současné době se využívá i k předzpracování a segmentaci obrazů ve stupních šedi. Jde o soubor metod využívajících vlastností bodových množin, výsledků z integrální geometrie a topologie ke zkoumání tvaru, kostry nebo konvexního obalu. Výsledek morfologických operací závisí pouze na rozmístění jednotlivých pixelů v obrazové matici, nikterak na jejich hodnotách. Založeny jsou převážně na zeštíhlování a roztahování zkoumaných obrazců. Základní morfologické metody jsou binární eroze, dilatace, skeletonizace otevření a uzavření. [6],[7]


Binární obraz lze vyjádřit 2D bodovou množinou. Body objektů v obraze reprezentují množinu  $X$ , což odpovídá jednotkovým pixelům. Body doplňku  $X^C$  popisují pozadí a reprezentují nulové pixely. Počátek má souřadnice (0,0) a souřadnice ostatních bodů je  $(x, y)$ . [6],[7]

#### Binární dilatace:

Používá se zejména k rozšíření objektů, vyplnění malých děr a úzkých zálivů v obrazech. Při binární dilataci sčítáme množinu  $X$  s množinou  $X'$ , které jsou navzájem od sebe posunuty o strukturální element  $B$ . Výsledkem dilatace je nová množina  $X$  větší nežli původní. [6],[7]

Minkovského součet: sjednocení posunutých množin

$$X \oplus B = \bigcup_{b \in B} X_b \quad (3.5)$$




Obr. 22: Binární dilatace

### Binární eroze:

Používá se zejména k zúžení a zjednodušení objektů. Předměty, které jsou menší než strukturální element, z obrazu zmizí. Při binární erozi se dvě množiny  $X$  a  $X'$  skládají pomocí Minkovského rozdílu. Jedná se o průnik všech posunů obrazu  $X$  o vektor  $-b \in B$ . Výsledkem dilatace je nová množina  $X$  menší nežli původní. [6],[7]


Minkovského rozdílu:

$$X \ominus B = \bigcup_{b \in B} X_{-b} \quad (3.6)$$



Obr. 23: Binární eroze

U tohoto projektu skrze Gaborovu filtraci vznikl obraz sítnice s výraznými bílými cévami, tmavým pozadím a nevhodným bílým okrajem kružnicového tvaru, viz Obr. 21. Odstranění této nechtěné obrazové informace se provede pomocí binární eroze. Vytvoří se erozní maska, viz Obr. 24 a aplikuje se na filtrovaný obraz.



Obr. 24: Erozní maska

### 3.3.3 Prahování

Prahování lze považovat za jednu ze základních a nejjednodušších metod segmentace obrazu. I přes vysoká omezení co se týče nastavení, je díky své jednoduchosti, implementaci, výpočetní nenáročnosti a časové úspoře široce používanou metodou.

Předměty a pozadí v obrazech mají převážně jinou úroveň intenzity jasu, proto je možné určit rozdílovou jasovou konstantu prahu (práh) k oddělení objektů od pozadí. Výsledkem prahování vzniká binární obraz, kde každý pixel s menší hodnotou než práh je stanoven jako pixel pozadí s hodnotou 0 a ostatní jako pixely segmentovaných předmětů. V dnešní době je možné prahovat s více prahy, kde výsledkem není binární snímek, ale obraz s omezeným počtem jasových úrovní. [4]

Problematika prahování nastává například v přítomnosti výrazného podílu šumu v obraze, kdy se rozložení jasu pixelů objektů a pozadí překrývá.

Binární prahování:

$$f(i, j) = \begin{cases} 1 & \text{pro } g(i, j) \geq P, \\ 0 & \text{pro } g(i, j) < P, \end{cases} \quad (3.7)$$

kde P je jasový práh, g (i, j) značí vstupní obraz a f (i, j) je výstupní prahovaný binární obraz. [10]

Prahovou konstantu lze stanovit interaktivně nebo pomocí automatických metod určování prahu. Pokusné určení prahu, kdy je použit pouze jeden globální statický práh má jen velmi úzké pole využití. Při segmentaci více podobných objektů v obraze není zpravidla možné úspěšně použít stejný práh na celé ploše obrazu, dokonce ani ve zcela jednoduchých scénách nemusí dát globální prahování s jediným prahem požadované segmentační výsledky. V těchto situacích se používá prahování s proměnným tzv. lokálním prahem. Mezi nejčastější metody patří metoda p-procentního prahu, metoda standardního histogramu nebo metoda váženého gradientu.[11]


Šedotónové prahování:

$$f(i, j) = \begin{cases} 1 & \text{prog}(i, j) \in P_1, \\ 2 & \text{prog}(i, j) \in P_2, \\ & \bullet \\ & \bullet \\ & \bullet \\ n & \text{prog}(i, j) \in P_n, \\ 0 & \text{jinak} \end{cases} \quad (3.8)$$

kde  $P_n$  je lokální jasový práh,  $g(i, j)$  značí vstupní obraz a  $f(i, j)$  je výstupní prahovaný obraz ve stupních šedi. [11]


Prahoání cévního řečiště umožňuje segmentovat cévy z filtrovaného obrazu sítnice, viz Obr. 21. Při navrhování prahu se vychází z procentuálního rozdělení obrazu na pozitivní a negativní sítnicovou informaci. Pozitivní informace jsou hlavní cévy a optický disk, negativní je pozadí, malé cévy a další struktury vzniklé filtrací. Prahová hodnota odpovídá globální jasové konstantě, vycházející z předem určeného počtu pozitivních pixelů. Z vytvořeného průzkumu vstupních testovacích dat vychází, že přibližně 5% celkového obrazu sítnice zastupují pixely hlavních cév a optického disku.

Prahová hodnota se pro každý obraz počítá automaticky z histogramu Gaborově filtrovaného snímku. Jasový práh se nastaví na hodnotu, kde postupný součet jednotlivých četností jasových složek ve směru od nejvyššího jasu 1 po nejnižší 0 musí být menší nebo roven 5% celkovému počtu obrazových bodů, viz Obr. 25.



Obr. 25: Histogram s vyznačeným prahem

Z Obr. 26 je patrný rozdíl mezi zvolenými hodnotami prahu. Pokud je práh nastaven nižší hodnotu, jak 5% ztrácí se potřebná informace pro budoucí modelování. V případě překročení je obraz zahlcen negativním segmentačním šumem, který by se musel složitě odstraňovat. Z tohoto důvodu je důležité mít prahovou hodnotu správně nastavenou. Ke zdokonalení segmentace by nepochybně pomohla jedna z automatických metod s lokálním prahováním, nicméně takto nastavené prahování poskytuje dostatečně dobré výsledky.




Obr. 26: Prahování s různými hodnotami prahu

### 3.3.4 Skeletonizace

Skeletonizace patří mezi morfologické metody, viz kap 3.3.2. Reprezentuje dekompozici 2D objektu na soustavu 1D křivek tzv. kostra (angl. skeleton), která nejlépe vystihuje tvar objektu. Jedná se o částečně reverzibilní transformaci, při které dochází k redukci a celkovému zjednodušení částí digitálního obrazu, podobně jako u eroze či otevření. Kostra je definována jako množina středů maximálních kružnic vepsaných segmentu. Popis předmětů digitálního obrazu pomocí kostry využívá mnoho algoritmů pro optické rozpoznávání znaků tzv. OCR, rozpoznávání otisků prstů, optickou kontrolu (snímání pohybu osob) nebo kompresi binárních obrazů. [14],[15]

Pro úspěšnou skeletonizaci je na kostru kladeno pět hlavních požadavků. Skelet musí ležet uvnitř objektu., nesmí obsahovat žádné elementy na pozadí, musí být spojitý jako originální objekt, nesmí se měnit topologie a kostra musí být co nejtenčí, pro 2D objekty nejlépe tloušťky 1 pixel. [14]

Existuje několik různých kategorií algoritmů pro vytváření koster objektů. První se označuje jako **metoda střední osy**. Je založena na vzdálenostech jednotlivých bodů od hranice regionu. Skelet reprezentuje množinou bodů, které jsou středy kružnic s maximálním poloměrem nacházejících se uvnitř regionu, viz Obr. 27. [15]



Obr. 27: Metoda střední osy

Druhou kategorií je tzv. **sekvenční ztenčování**. Princip je postaven na postupném snižování hranice tloušťky objektu v závislosti na strukturním elementu, dokud se nedosáhne hodnoty jeden pixel. [14]

Definice ztenčování:

$$X \oplus B = X \setminus (X \ominus B) \quad (3.10)$$

kde  $X$  je digitální binární obraz,  $B$  značí strukturní element. [7]




Obr. 28: Sekvenční ztenčování [20]

Skeletonizací lze docílit značného snížení objemu dat, který pro některé algoritmy je nežádoucím faktorem. Při modelování cévního řečiště je tloušťka jednotlivých cév z počátku důležitou vlastností, z důvodu rozlišení na cévy hlavní a vedlejší. Nicméně v určité sekci modelovacího algoritmu se stává směr cév hlavní charakteristikou a tím tloušťka ztrácí na významu. Skeletonizací prahovaného obrazu sítnice vzniká směrodatná struktura cévního řečiště, viz Obr. 29.

Prahovaný obraz

Kostra



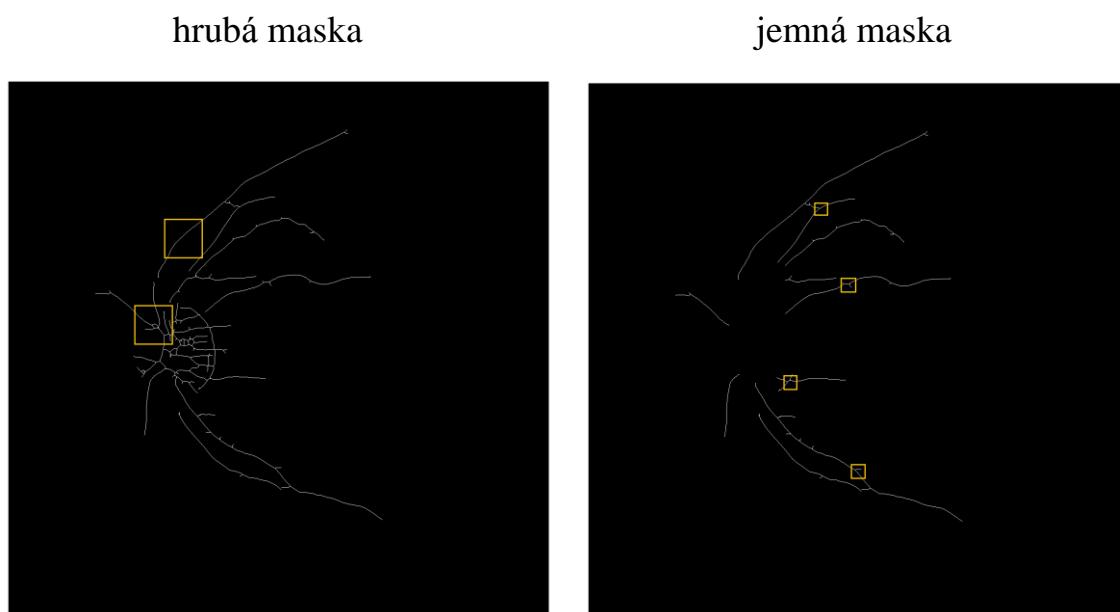
Obr. 29: Skeletonizace cévního řečiště

### 3.4 Úprava binárních snímků

Část úpravy binárních snímků zajišťuje finální korektury segmentovaných obrazů cévního řečiště. Po segmentaci zůstávají v obraze, úseky částečně nepotřebné obrazové informace, které je pro optimální modelaci potřeba odstranit. Tato část algoritmu se prolíná s aproximací a modelováním, z důvodu částečného využití neupraveného snímku pro detekci optického disku, viz Kap. 3.5.1. Pro následující aproximace jsou informace popisující optický disk nežádoucí, proto je třeba je odstranit.

Je postavena na principu krokového prohledávání obrazu a následném odstraňování

oblastí o určitém obsahu bílých bodů. Vychází se z faktu, kde maska přiložená na samostatnou část cévy bude obsahovat méně bodů než maska přiložená na část s optickým diskem, nebo na místa větvení cév. Vzniknou krátké oddělené úseky, které se odstraní a vyčistí tak obraz. Toto prohledávání je provedeno ve dvou úrovních a to v hrubém a jemném čištění. Liší se v závislosti na velikosti zvolených masek.



Obr. 30: Finální úpravy binárních snímků sítnice




Obr. 31: Koncový výsledek zpracování testovacího obrazu

## 3.5 Aproximace a modelování

Modelování cévního stromu je jednou z hlavních částí této diplomové práce. Má za úkol vytvořit matematický model popisující směr hlavních cév sítnice.

Cévy ve vrstvě sítnice vytváří tzv. hlavní cévní oblouk, viz Obr. 32, který se skládá z horní (S) a dolní (I) části. Smyslem modelu je tento oblouk co nejlépe charakterizovat a zjednodušit. Do realizace modelu jsou aplikovány tři hlavní modelovací funkce: parabolická, lineární a kvartická.



Obr. 32: Hlavní cévní oblouk [1]


### 3.5.1 Aproximace vrcholu

Vrchol (O) je takový bod, který co nejvěrohodněji popisuje střed optického disku (OD) a zároveň je pojícím bodem pro horní a dolní cévní oblouk, viz Obr. 32. Tento vrchol není vždy jednoduché nalézt a provedlo se již na toto téma několik studií. Tato práce se přesnou detekcí středu optického disku nezabývá. Z tohoto důvodu postačí, pro počáteční kroky modelování, vrchol optického disku jen přibližně stanovit.

Aproximace vrcholu je postavena na obdobném principu jako úprava binárních snímků, viz Kap. 3.4. V níž na základě velikosti detekční masky se postupně zkoumá procentuální obsah bílých bodů v segmentovaném obrazu sítnice. Hrana čtvercové masky odpovídá přibližně průměru optického disku.

Místo s nejhustším zastoupením bílých bodů v největší míře odpovídá optickému disku. Aproximací vrcholu se dosáhlo třech různých variant výsledků, viz Obr. 33. První variantou je určení vrcholu uvnitř optického disku, tento výsledek je považován

za ideální. Pokud je vrchol detekován na obvodu optického disku stále se jedná o dobrý výsledek a to z důvodu relativně malé velikosti optického disku. Nalezený bod lze stále považovat za vrchol. Za špatný výsledek aproximace lze chápat případ, kdy vrchol leží mimo optický disk. Toto je způsobeno převážně hustým cévním řečištěm detekovaným mimo oblast optického disku.

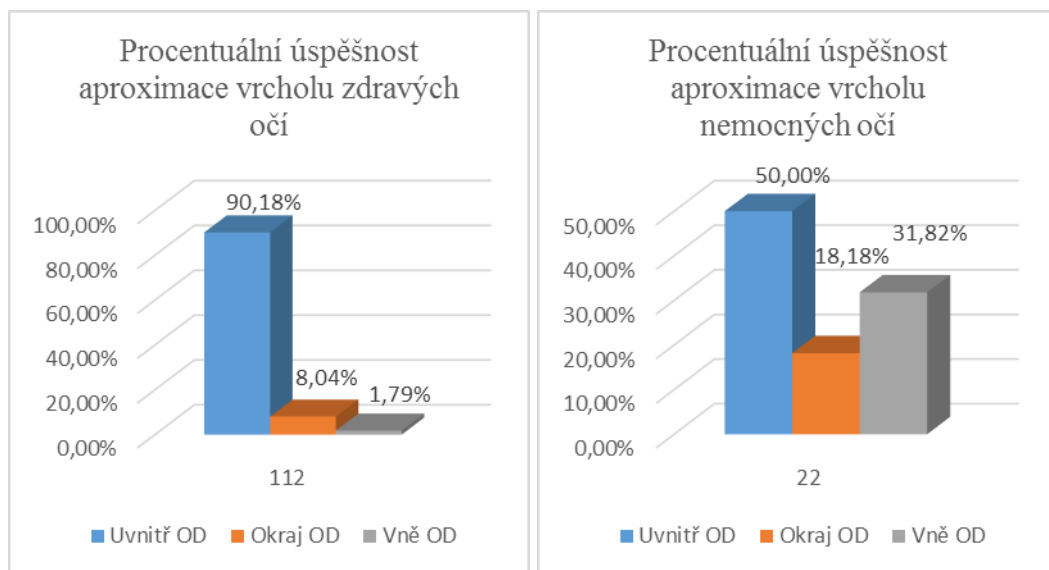


Obr. 33: Různé výsledky aproximace vrcholu

Aplikací aproximace vrcholu na dva soubory testovacích dat, 112 zdravých a 22 nemocných očí, byla zjištěna následující fakta, viz Obr. 34. Pokud se jednalo o zdravé pacienty, probíhala aproximace bez problémů. Pouze ve 2 případech se určil vrchol vně optického disku.

U snímků pacientů s diabetickou retinopatií, nastávají určité komplikace. Z důvodu nevýrazného zobrazení optického disku a přítomnosti rušivých elementů se modelovaný vrchol nacházel, uvnitř optického disku, pouze u poloviny testovacích snímků. Přesto v kategorii výsledků nemocných pacientů, které lze označit jako „dobré“ detekuje zvolená metoda, téměř v 70% případů, vrchol cévního oblouku správně.

Detekce optického disku umožňuje rozlišit snímky pravého a levého oka. Stranová informace je důležitým faktorem modelovacího algoritmu. V případě detekce pravého oka je obraz zrcadlově převrácen a modelování probíhá stejně jako u levého oka. Sníží se tím nároky na programovací algoritmus.



Obr. 34: Procentuální úspěšnosti aproximace vrcholu

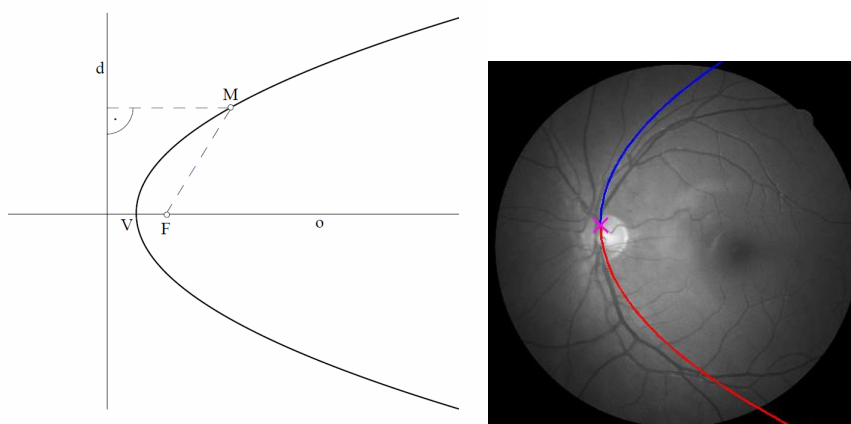
### 3.5.2 Aproximace matematickou funkcí

#### Parabola

Parabola je množina bodů v rovině, které mají od daného bodu  $F$  a dané přímky  $d$  stejnou vzdálenost, viz Obr. 35. Bod  $F$  se nazývá *ohnisko*, přímka  $d$  je řídicí přímka.

$$(y - n)^2 = 2p(x - m) \quad (3.11)$$

kde parametr  $p$  je vzdálenost ohniska od řídicí přímky a  $[m, n]$  souřadnice vrcholu  $V$ . [16]




Obr. 35: Parabolická aproximační funkce [16]

### Lineární funkce

Lineární funkce je taková funkce, jejíž hodnota na celém jejím definičním oboru rovnoměrně klesá nebo roste.

$$y - n = k(x - m) \quad (3.12)$$

kde parametr  $k$  je lineární koeficient určující směr přímky, a  $[m, n]$  souřadnice posunutí.



Obr. 36: Lineární aproximační funkce

### Kvartická funkce



Kvartická funkce je speciálním případem polynomické funkce. Kde polynomická funkce je každá funkce ve tvaru:

$$f(x) = a_m x^m + a_{m-1} x^{m-1} + a_{m-2} x^{m-2} + \dots + a_1 x + a_0 \quad (3.13)$$

Kvartická funkce:

$$(y - n)^4 = r(x - m) \quad (3.14)$$

kde parametr  $r$  určuje otevření kvartické křivky, a  $[m, n]$  souřadnice vrcholu.



Obr. 37: Kvartická aproximační funkce

### 3.5.3 Modelování cévního oblouku

Modelování vychází z metody minimalizace vzdáleností mezi body aproximační funkce a body cévního oblouku. Tuto kriteriální funkci lze zapsat následovně:

$$E = \sum_{i=1}^M f(P_i A_{iMIN}) \quad (3.15)$$

$$f(P_i A_{iMIN}) = \sqrt{(x_{P_i} - x_{A_{iMIN}})^2 + (y_{P_i} - y_{A_{iMIN}})^2} \quad (3.16)$$

$$A_{iMIN} = \text{MIN}(|P_i A_j|) \quad (3.17)$$

kde E je celková optimalizační vzdálenost, P jsou body aproximační funkce, M je počet všech bodů aproximační funkce a body A náleží cévnímu řečišti.

Výpočet minimalizace je obsažen ve vytvořené funkci MinFun\_JV, která je pro ukázkou k dispozici v příloze B.

Algoritmus hledá k bodu P aproximační funkce vždy nejbližší možný bod A cévního oblouku a vytváří minimalizované páry, např. ( $|PA_2| < |PA_1|$ ), viz Obr. 38a. Tento krok se opakuje pro všechny body aproximační křivky. Předpokladem pro lepší optimalizaci je váhování bodů v blízkosti optického disku. Tím by se měl zajistit větší vliv těchto bodů na kriteriální funkci a jednotlivé aproximační křivky by měli lépe kopírovat hlavní oblouk. Každý pár spadající do oblasti, opané kružnicí o středu ve vrcholu O s poloměrem odpovídajícím průměru optického disku, je se vzdáleností od vrcholu sestupně váhován. Maximální hodnota váhy je nastavena na 10 a sestupuje k 1. Vznikne vektor váhovaných párových vzdáleností, které se sečtou a vytvoří celkovou optimalizační vzdálenost E.

Použití váhy má velký vliv na úspěšnost optimalizace. V případě kdy vektor vzdáleností není váhován dochází u některých obrázků v optimalizační funkci ke kolapsu.

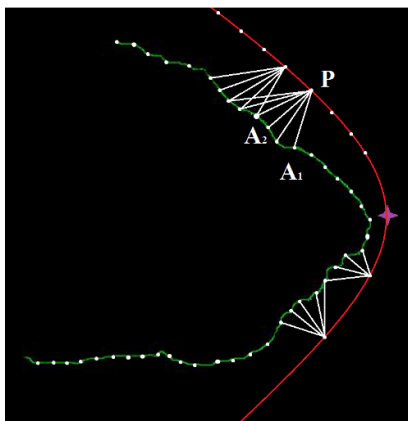
Optimalizaci má na starosti systémová funkce výpočetního systému MATLAB – fminsearch. Tato funkce využívá Nelder-Meadovu simplexovou metodu, která k nalezení minima funkce nepoužívá derivace. Syntaxe:

$$x = \text{fminsearch}('aproximacni\_funkce', x_0) \quad (3.18)$$

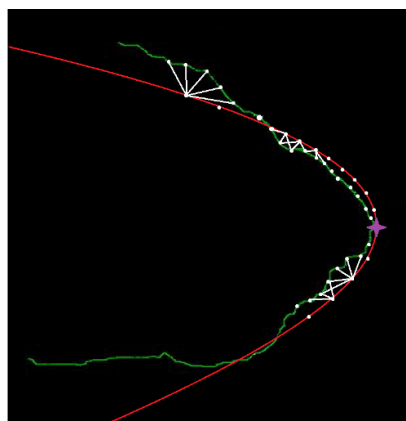
kde  $x_0$  je počáteční hodnota iterativního vyhledávání a x je výsledné minimum. Hodnoty  $x_0$  a x mohou být skaláry, vektory nebo matice, v závislosti na počtu vstupních proměnných „aproximacni\_funkce“. Výstupní hodnotou této funkce musí být skalární veličina a odpovídá jí celková optimalizační vzdálenost.

Výsledkem optimalizace pomocí `fminsearch` jsou parametry popisující nový model aproximační funkce, viz Obr. 38b.

a) počáteční aproximace



b) výsledný model



Obr. 38: Modelování parabolou


Prvním krokem modelování je optimální zvolení počátečních parametrů  $x_0$  aproximačních funkcí. Parametry  $p$ ,  $k$  a  $r$  jsou hlavními parametry aproximačních matematických funkcí, určující tvar modelů cévního oblouku, viz Kap. 3.5.2. Z důvodu robustnosti jsou jejich počáteční hodnoty nastavené tak, že model je v počátku více otevřený a uzavírá se k cévnímu oblouku, viz Obr. 38. Při opačném nastavení, kdy se model otevírá k cévnímu oblouku, dochází často k chybné minimalizaci. Výsledný model má tvar vodorovné úsečky.

Souřadnice  $[m, n]$  určují pozici vrcholu aproximačních funkcí. Vrchol je fixního nebo proměnného charakteru. Za fixní vrchol se považuje takový bod, který po provedení optimalizace nemění svoje souřadnice. Naopak dynamický vrchol mění svoje souřadnice společně s ostatními body aproximační funkce, viz Obr. 39.

a) statický vrchol



b) dynamický vrchol



Obr. 39: Duální modelování

Modelování cévního oblouku lze provést singulárně nebo duálně. Výsledkem singulárního modelování je osově souměrná aproximační funkce. Duální optimalizace separátně modeluje horní a dolní cévní oblouk – tedy dostaneme dvě různé hodnoty parametrů  $p$ , viz Obr. 39.

Optimální nastavení počátečních hodnot aproximačních funkcí vychází ze subjektivního vyhodnocení tvarů jednotlivých aproximačních funkcí. Problém nastává u některých zvolených hodnot, při kterých dochází k chybě optimalizační funkce `fminsearch`. V některých případech se stává, že se model postupně aproximuje mimo oblast obrazu. Z důvodu této problematiky se u parabolické aproximace musí zvolit jiné nastavení u duální a singulární detekce.

*Počáteční parametry:*

Singulární optimalizace: parabola ( $p=300$ ), lineární funkce ( $k=1$ ) a kvartická ( $r=10^8$ )

Duální optimalizace: parabola horní č. ( $p=200$ ), parabola dolní č. ( $p=400$ ), kvartická a lineární mají shodné parametry se singulárním

### 3.6 Export a zobrazení výsledků

Posledním krokem modelovacího algoritmu je uložení všech důležitých výsledků. Hlavní výstupní data jsou rozdělena do subjektivní a objektivní kategorie.

Subjektivní skupinu reprezentují obrazové výsledky hlavních sekcí programu, viz Obr. 40. Patří sem výsledky předzpracování, Gaborovy filtrace, segmentace a skeletonizace, úpravy binárních snímků a konečného modelování. Model se ukládá ve dvou verzích. V první verzi je model zobrazen ve snímku hlavních detekovaných cév. Tato expozice umožňuje vyhodnocení metody podle bodů, ze kterých se výsledný model vytvářel. Druhá verze modelu je vložena do nesegmentovaného obrazu oční sítnice, dovoluje tak posoudit aproximaci v reálném prostředí.


Objektivní kategorie se zakládá na vstupních a výstupních parametrických hodnotách optimalizační funkce. Náleží sem souřadnice aproximačního vrcholu  $[m, n]$ , parametry  $p$ ,  $k$ ,  $r$  a hodnota celkové optimalizační vzdálenosti. Algoritmus vkládá tyto informace do souboru tabulkového editoru Microsoft Excel. V tomto editoru je vytvořen skript, který automaticky z vložených dat provede statistické hodnocení modelovacího algoritmu.

Všechny získané výsledky lze nalézt na přiloženém DVD v sekci „Výsledky modelování“.


a) Předzpracování




b) Gaborova filtrace




c) Segmentace a skeletonizace




d) Úprava binárních snímků



e) Model v segmentovaném obraze



f) Model v předzpracovaném obraze



Obr. 40: Výsledky sekci modelovacího algoritmu

## 4 ZPRACOVÁNÍ VÝSLEDKŮ

Všechny získané výsledky jsou statisticky rozpracovány a diskutovány v této kapitole. Testována je kvalita přesnosti a robustnost metody detekce cévního stromu. Vlastnosti byly testovány na definovaných sadách retinálních snímků, viz Kap. 2. K dispozici bylo 112 zdravých a 22 nemocných obrazů sítnice o různé kvalitě a rozlišení. Snaha je o co nejobektivnější posouzení vytvořené metody, ale z důsledku malého počtu vhodných testovacích dat je ovlivněna subjektivním posouzením jednotlivých kritérií správnosti.

Zpracovávají se výsledky dvou hlavních kategorií nastavení modelovacího algoritmu. Jedná se o statickou a dynamickou volbu vrcholu aproximační funkce, viz Kap. 3.5.3. V závislosti na vybrané kategorii se hodnotí výsledky modelování definovaných aproximačních funkcí.

### 4.1 Přesnost modelovacího algoritmu

Přesnost vychází z hodnocení rovnosti vytvořených modelů vždy dvou snímků stejného oka. Toto hodnocení je provedeno pouze pro sadu zdravých očí, protože u nemocných nejsou k dispozici data shodných očí. Postaveno je na absolutní chybě, která vyjadřuje, o kolik se liší model prvního snímku od druhého.

$$\text{abs} = |p1 - p2| \quad (4.1)$$

kde  $p1$  a  $p2$  jsou parametry modelovacích aproximačních funkcí.

Hodnotí se zvlášť přesnost správného umístění aproximační funkce a zvlášť její tvar. **Kritérium umístění** vychází z poloměru optického disku, který odpovídá průměrné hodnotě 100 pixelů:

$$\begin{aligned} \text{abs\_vrchol} \in 0 - 10\% \quad \text{rOD} &\rightarrow \text{velmi dobrá kvalita} \\ \text{abs\_vrchol} \in 10 - 30\% \quad \text{rOD} &\rightarrow \text{dobrá kvalita} \\ \text{abs\_vrchol} \in 30 - 50\% \quad \text{rOD} &\rightarrow \text{špatná kvalita} \\ \text{abs\_vrchol} > 50\% \quad \text{rOD} &\rightarrow \text{velmi špatná kvalita} \end{aligned} \quad (4.2)$$

kde  $\text{abs\_vrchol}$  je absolutní chyba pozice vrcholu a  $\text{rOD}$  je poloměr optického disku.

**Kritérium přesnosti tvaru** aproximační funkce, závisí na subjektivním posouzení. Nejprve je určena mezní hodnota jednotlivých parametrů ( $p$ ,  $k$ ,  $r$ ), která popisuje situaci, při které je změna tvaru aproximační funkce subjektivně vnímatelná. Mezní hodnoty

jsou stanoveny takto: parabolická (100), lineární (1) a kvartická ( $10^7$ ). Kritérium se určí následovně:


$$\begin{aligned}
 \text{abs\_par} \in 0 - 10\% & \text{ MH} \rightarrow \text{velmi dobrá kvalita} \\
 \text{abs\_par} \in 10 - 30\% & \text{ MH} \rightarrow \text{dobrá kvalita} \\
 \text{abs\_par} \in 30 - 50\% & \text{ MH} \rightarrow \text{špatná kvalita} \\
 \text{abs\_par} > 50\% & \text{ MH} \rightarrow \text{velmi špatná kvalita}
 \end{aligned}
 \tag{4.3}$$

kde, abs\_par je absolutní chyba parametru aproximační funkce a MH je mezní hodnota kvality přesnosti.


#### 4.1.1 Statické souřadnice vrcholu aproximační funkce

##### A) Určení přesnosti umístění funkce:

Statický vrchol je určen metodou aproximace vrcholu, viz Kap. 3.5.1, nepodléhá tedy optimalizaci, a proto je pro všechny aproximační funkce stejný.



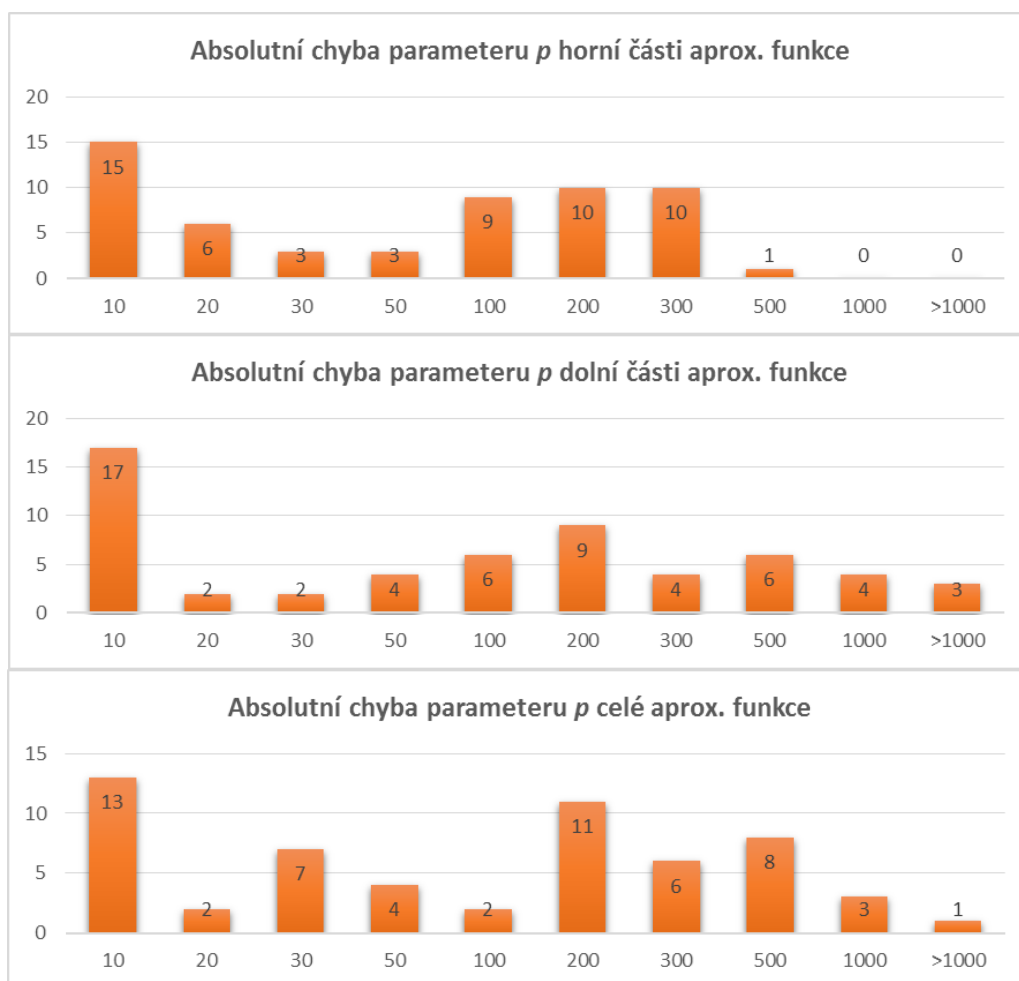
Obr. 41: Rozložení absolutní chyby na celém spektru testovacích dat.






Obr. 42: Procentuální vyhodnocení kvality přesnosti

**B) Určení přesnosti tvaru modelovací funkce:**

Parabolická funkce:






Obr. 43: Rozložení absolutní chyby na celém spektru testovacích dat






Obr. 44: Procentuální vyhodnocení kvality přesnosti

Lineární funkce:






Obr. 45: Rozložení absolutní chyby na celém spektru testovacích dat






Obr. 46: Procentuální vyhodnocení kvality přesnosti

Kvartická funkce:



Obr. 47: Rozložení absolutní chyby na celém spektru testovacích dat




Obr. 48: Procentuální vyhodnocení kvality přesnosti


## 4.1.2 Dynamické souřadnice vrcholu aproximační funkce

### A) Určení přesnosti vrcholu funkce:

Parabolická funkce:





Obr. 49: Rozložení absolutní chyby na celém spektru testovacích dat




Obr. 50: Procentuální vyhodnocení kvality přesnosti

Lineární funkce:




Obr. 51: Rozložení absolutní chyby na celém spektru testovacích dat




Obr. 52: Procentuální vyhodnocení kvality přesnosti

Kvartická funkce:





Obr. 53: Rozložení absolutní chyby na celém spektru testovacích dat






Obr. 54: Procentuální vyhodnocení kvality přesnosti

## B) Určení přesnosti tvaru modelovací funkce:

Parabolická funkce:




Obr. 55: Rozložení absolutní chyby na celém spektru testovacích dat






Obr. 56: Procentuální vyhodnocení kvality přesnosti

Lineární funkce:





Obr. 57: Rozložení absolutní chyby na celém spektru testovacích dat






Obr. 58: Procentuální vyhodnocení kvality přesnosti

Kvartická funkce:



Obr. 59: Rozložení absolutní chyby na celém spektru testovacích dat



Obr. 60: Procentuální vyhodnocení kvality přesnosti

### 4.1.3 Celkové zhodnocení kvality přesnosti

Kvalita přesnosti modelovacího algoritmu									
Statická metoda					Dynamická metoda				
aproximační funkce	část funkce	velmi dobrá	dobrá	pozitivní suma	aproximační funkce	část funkce	velmi dobrá	dobrá	pozitivní suma
Parabolická	horní p	26%	16%	42%	Parabolická	horní p	32%	7%	39%
	dolní p	30%	7%	37%		dolní p	16%	16%	32%
	celá p	23%	16%	39%		celá p	12%	27%	39%
	souř. x	80%	8%	88%		souř. x	31%	26%	57%
	souř. y	69%	12%	81%		souř. y	26%	33%	59%
Lineární	horní k	34%	19%	53%	Lineární	horní k	30%	30%	60%
	dolní k	25%	18%	43%		dolní k	21%	26%	47%
	celá k	21%	19%	40%		celá k	39%	24%	63%
	souř. x	80%	8%	88%		souř. x	29%	23%	52%
	souř. y	69%	12%	81%		souř. y	16%	35%	51%
Kvartická	horní r	47%	18%	65%	Kvartická	horní r	70%	9%	79%
	dolní r	84%	11%	95%		dolní r	75%	7%	82%
	celá r	82%	7%	89%		celá r	40%	25%	65%
	souř. x	80%	8%	88%		souř. x	18%	26%	44%
	souř. y	69%	12%	81%		souř. y	16%	34%	50%

Tab. 1: Souhrn kvality přesnosti modelovacího algoritmu

Hodnotícím kritériem této sekce je tzv. pozitivní suma přesnosti, která je dána součtem velmi dobré a dobré kvality.

#### **Kvalitu přesnosti umístění:**

Jednoznačně nejlepší kvalitu přesnosti umístění dosahuje modelovací algoritmus při nastavení statického vrcholu. 88% přesnost x-ové souřadnice a 81%. Pokud jde pouze o dynamické modelování, zde nejlepších výsledků nabývá modelování parabolou  $x=57%$  a  $y=59%$ . Což je téměř o 30% horší než u statické aproximace.

U kvality dynamického umístění není zaznamenán žádný výrazný rozdíl mezi jednotlivými aproximačními funkcemi. Pokud se jedná o velmi dobrou kvalitu, dosahuje nejlepších výsledků jednoznačně parabola. Ta je místy o více jak 10% kvalitnější než ostatní dvě aproximační funkce.

Metoda statické modelace vrcholu nepodléhá optimalizaci. Vrchol se tedy nemění společně s tvarem aproximační funkce. Proto nemá vliv na případný větší posun vrcholu. Z tohoto vyplývá, že dynamické modelování vrcholu závisí více kvalitě segmentovaného obrazu než statická metoda.

### **Kvalita přesnosti tvaru:**

Pokud by se hodnotily obecně obě dvě metody, statická a dynamická, vycházely by průměrné přesnosti obou metod stejně a to přibližně 56%. Nicméně pokud se jedná o různé funkce jednotlivých kategorií, musí se hodnotit odděleně.

#### *Parabolická funkce:*

Fixní model dosahuje lepších výsledků ve všech třech kategoriích modelování horního, dolního a celého cévního oblouku a to převážně způsobenou vyššími hodnotami velmi dobré kvality. Ty bývají i dvakrát větší než u proměnného modelu.

#### *Lineární funkce:*

U této funkce naopak dosahuje lepších kvalit metoda dynamická. A to hlavně při modelování celého cévního stromu kde dosahuje přesnosti až 63%.

#### *Kvartická funkce:*

Procentuálně nejpresnější funkce modelování, průměrně dosahuje kvalit kolem 80%. Zde se hodnoty přesnosti různého modelování cévního stromu liší. Pro horní model dosahuje nejlepších výsledků dynamická funkce a to celých 14%. Pro dolní a celý model vyhrává naopak statické nastavení.

Z hlediska kvality přesnosti dosahuje úplně nejlepších výsledků kvartická statická metoda.

## **4.2 Robustnost modelovacího algoritmu**

Robustnost je subjektivní hodnocení modelovacího algoritmu, při kterém se pozoruje, zda výsledný model alespoň přibližně aproximuje cévní oblouk. Hodnotí se jak u zdravých, tak u nemocných retinálních snímků.


Tabulka robustnosti modelovacího algoritmu na sadě zdravých retinálních snímků							
Statická metoda				Dynamická metoda			
aproximační funkce	část funkce	počet vadných modelů	procentuální úspěšnost	aproximační funkce	část funkce	počet vadných modelů	procentuální úspěšnost
Parabolická	celá	13	88,18%	Parabolická	celá	8	92,73%
	horní	16	85,45%		horní	35	68,18%
	dolní	3	97,27%		dolní	15	86,36%
Lineární	celá	0	100,00%	Lineární	celá	1	99,09%
	horní	3	97,27%		horní	0	100,00%
	dolní	0	100,00%		dolní	1	99,09%
Kvartická	celá	3	97,27%	Kvartická	celá	2	98,18%
	horní	4	96,36%		horní	2	98,18%
	dolní	2	98,18%		dolní	3	97,27%

Tab. 2: Robustnost modelovacího algoritmu - zdravé oči

Tabulka robustnosti modelovacího algoritmu na sadě nemocných retinálních snímků							
Statická metoda				Dynamická metoda			
aproximační funkce	část funkce	počet vadných modelů	procentuální úspěšnost	aproximační funkce	část funkce	počet vadných modelů	procentuální úspěšnost
Parabolická	celá	9	57,14%	Parabolická	celá	5	76,19%
	horní	11	47,62%		horní	5	76,19%
	dolní	8	61,90%		dolní	4	80,95%
Lineární	celá	6	71,43%	Lineární	celá	6	71,43%
	horní	7	66,67%		horní	6	71,43%
	dolní	5	76,19%		dolní	7	66,67%
Kvartická	celá	6	71,43%	Kvartická	celá	6	71,43%
	horní	9	57,14%		horní	10	52,38%
	dolní	8	61,90%		dolní	7	66,67%

Tab. 3: Robustnost modelovacího algoritmu - nemocné oči

Robustnost metody u zdravých obrazů je, podle očekávání, daleko vyšší než u nemocných, protože program byl vytvářen pomocí jejich charakteristik. U nemocných očí hrají velkou roli na kvalitě modelování přítomné patologické struktury a změna struktury jednotlivých vrstev sítnice (např. jejich tloušťka), což má vliv na výslednou kvalitu obrazu. Tyto faktory znemožňují korektní aproximaci, viz Obr. 61. Nicméně i u nemocných pacientů lze tento modelovací algoritmus hodnotit za pozitivní.



Obr. 61: Nekorektní výsledný model

Stejně jako při rozhodování o kvalitě přesnosti, jsou k dispozici různé kombinace modelovacích částí, viz Tab. 2 a 3. Z tabulek vychází zajímavost, při které u zdravých snímků se jako nejlepší aproximační funkce prokazuje lineární - jak statická, tak dynamická. A tou s nejhorší kvalitou je parabolická dynamická funkce. Naopak u nemocných obrazů je nejlepší aproximační metodou právě parabolická dynamická funkce. U nemocných pacientů není k dispozici takové množství testovacích dat a subjektivní hodnocení bylo prováděno pouze jednou osobou. Tato fakta mají nejspíš největší vliv na onu anomálii.

### 4.3 Celkové zhodnocení modelovacího algoritmu

Modelovací algoritmus, jak již bylo zmíněno, je navrhován pomocí sady zdravých retinálních snímků. Z tabulek pro robustnost i přesnost se jeví za jednoznačně nejlepší metodu kombinace statického určení vrcholu a kvartické aproximační funkce. Přesto ze subjektivního hlediska nedosahuje kvalit modelu s dynamickým určením vrcholu a lineární aproximační funkcí. Tento model je kvalitní, jak z hlediska robustnosti a přesnosti, tak z hlediska subjektivního vyhodnocení kvality aproximace cévního oblouku. Přímkou velmi efektivně modelují směr cévního stromu, daleko přesněji než kvartická funkce, která je místy velmi otevřená a nepřibližuje se k cévnímu oblouku.

Parabolická funkce je trochu zklamáním. Přestože v ideálních případech nejlépe popisuje cévní oblouk a to jak při nastavení statickém tak dynamickém. Hlavní příčinou jsou velké rozdíly v jasů u početné části retinálních testovacích snímků, které byly během konstrukce aproximačního modelu opomenuty. Proto se liší segmentované obrazy, z jejichž informací je optimalizován model cévního oblouku. Druhým

problémem je optimalizační funkce `fminsearch`, která nezaručuje nalezení globálního minima optimalizační funkce. To neumožňuje v některých případech nalézt globální optimální aproximaci a je velmi závislá na vstupních počátečních parametrech.

Lze však konstatovat, že pokud by se podařilo docílit shodných kvalitních jasových složek, stejných párů očních snímků, probíhala by optimalizace takto připravenou modelovací funkcí daleko lépe. A zároveň by dosahovala vyšších kvalit z pohledu robustnosti i přesnosti.

## ZÁVĚR

V práci se úspěšně podařilo vytvořit modelovací algoritmus hlavního cévního oblouku. Byly nastudovány a aplikovány jednotlivé metody zpracování obrazu. Jednotlivá nastavení modelovacího algoritmu byla zkoušena testovacím programem, kterým prošlo 112 zdravých a 22 nemocných snímků sítnice. Všechny vlastnosti jednotlivých modelů byly graficky a tabulkově zpracovány a vyhodnoceny. Vyhodnocením se zjistila řada nedostatků, která by při odstranění výrazně zlepšila kvalitu algoritmu.

V programu je aplikována sada Gaborových filtrů, které jsou upraveny tak aby zvýrazňovaly hlavní cévy ve směrech  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  a  $135^\circ$  pro široké spektrum testovacích obrazů. Gaborovy filtry zvýrazňují potřebné cévy a potlačují vše ostatní. Parametry jsou nastaveny na pevně, z čehož plynnou různé navazující komplikace. Parametry jednotlivých filtrů jsou závislé na hodnotě jasu jednotlivých snímků. Pro vylepšení se doporučuje nastavit filtry v závislosti na kvalitě jasu, nebo jas před filtrací standardizovat.

Prahování je druhá důležitá část, kde volba prahu se poloautomaticky mění. Závisí na jasu snímku, ale práh je nastaven staticky jako procentuální hodnota jasu (5%). Hodnota byla zvolena na základě testování různých hodnot prahu na sadě 6 různých snímků. Po celkovém vyhodnocení byl zjištěn fakt, že při zpracování hodně tmavých obrázků dochází prahováním k velké ztrátě kladné obrazové informace. To podporuje předešlou teorii o unifikaci jasu.

Hlavní modelovací část úspěšně vytváří parabolickou, lineární a kvartickou aproximační funkci, s pevným nebo proměnným vrcholem. Tento vrchol je v ideálním případě umístěn ve středu optického disku.

Testováním byla zjištěna, celková průměrná kvalita přesnosti modelovacího algoritmu u statického vrcholu 67% a u dynamického pouze 55%. Tato přesnost určuje, jak moc jsou si výsledky modelování dvou snímků stejného oka podobné. Podrobnější výsledky se nacházejí v kapitole 4.1.3. Očekávány byly o něco lepší výsledky. Přesnost je závislá na kvalitě výstupních obrazů ze sekce segmentace, kde dochází ke ztrátám informace. Neuspokojivé výsledky částečně ovlivnila i zvolená optimalizační funkce `fminsearch`, která vyhledává pouze lokální minima a závisela do jisté míry na počátečních parametrech.

Robustnost metody je daleko vyšší než přesnost metody. U velkého množství testovacích snímků se vymodeluje dostatečně kvalitně hlavní cévní oblouk. Nejlepších výsledků dosahuje lineární aproximační funkce, která nejlépe popisuje směr. Celkový tvar nejlépe popisuje parabolická funkce, ale nedosahuje takových kvalit jako funkce lineární. Kvartická funkce má jistý potenciál, protože na rozdíl od funkcí lineární a parabolické je více uzavřená a lépe tak kopíruje konce cévního oblouku. Z důvodu vysoké hodnoty počátečního parametru  $r=10^8$  však neumožňuje funkce fminsearch v některých případech větší manipulaci s jejím tvarem, z důvodu vyhledávání lokálních minim. Pokud by se startovací parametr  $r$  upravil například tak, že by se nastavil na hodnotu  $10$  a zbytek  $10^7$  se doplnil konstantou, mohla by snad optimalizace dosahovat lepších výsledků.

Celkově se dá hodnotit modelovací algoritmus za funkční. Po důkladném testování bylo objeveno několik nedostatků, na kterých se dá do budoucna zapracovat a metodu dovézt k lepším výsledkům.

# LITERATURA

- [1] OLOUMI, F., RANGAYYAN, R. M., ELLS a A. L. *Parabolic Modeling of the Major Temporal Arcade in Retinal Fundus Images*. IEEE Transactions on Instrumentation and Measurement. 2012, roč. 61, č. 7, s. 1825-1838.
- [2] RANGAYYAN R. M., AYRES F. J., OLOUMI F., OLOUMI F. a ESHGHZADEH-ZANJANI P. *Detection of blood vessels in the retina with multiscale Gabor filters*. *Journal of Electronic Imaging*. 2008, roč. 17, č. 2, s. 023018-023018-7.
- [3] OLOUMI, F., RANGAYYAN, R.M., ELLS, “*Dual-parabolic modeling of the superior and the inferior temporal arcades in fundus images of the retina,*” in Proc. IEEE MeMeA, Bari, Italy, Jun. 2011, pp. 1–6.
- [4] DOBEŠ, M.: *Zpracování obrazu a algoritmy v C#*. BEN Praha, 2008, ISBN 978-80-7300-233-6.
- [5] AACH, T.; Kaup, A.; Mester, R.: *On texture analysis: Local energy transforms versus quadrature filters*. In *Signal Processing*, vol. 45, pp. 173-181, 1995.
- [6] GOUSIAS, J., Vincent L., Bloomberg D. S.: *Mathematical Morphology and Its Applications to Image and Signal Processing*, Kluwer Academic Publisher, 2000.
- [7] SERRA, J. *Image Analysis and Mathematical Morphology*, Academic Press, 1982
- [8] BAŠE, M. *Detekce bifurkací cévního řečiště na sítnici*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 49 s. Vedoucí diplomové práce doc. Ing. Radim Kolář, Ph.D..
- [9] SEVERA, D. *Oftalmologická zařízení pro vyšetřování sítnice* Brno: Masarykova univerzita v Brně, Lékařská fakulta 2009. 134 s. Vedoucí bakalářské práce MUDr. Jan Richter..
- [10] ŠONKA, M., HLAVÁČ, V., BOYLE, R.: *Image Processing, Analysis, and Machine Vision*, Chapman&Hall, 1993
- [11] PLUSKAL, R. *Dohledávání objektů v obraze*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2008. 68 s. Vedoucí diplomové práce Ing. Miloslav Richter, Ph.D.
- [12] HÁJOVSKÝ, R., PUSTKOVÁ, R., KUTÁLEK, F.: *Zpracování obrazu v měřicí a řídicí technice* Ediční středisko VŠB-Technická univerzita Ostrava, 2012, ISBN 978-80-248-2596-0

- [13] TOBIÁŠOVÁ, N. Detekce mikroaneuryzmat a hemoragií ve snímcích sítnice. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012. 61 s. Vedoucí bakalářské práce doc. Ing. Radim Kolář, Ph.D..
- [14] KLETTEN, G. *Skeletons in Digital Image Processing*. Computer Science Department of The University of Auckland, 2002.
- [15] DVOŘÁK, P. *Popis objektů v obraze*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 62 s. Vedoucí diplomové práce Ing. Martin Zukal.
- [16] PECH, P.: *Kuželosečky*. Jihočeská univerzita v Českých Budějovicích, České Budějovice, 2004, ISBN 80-7040-755-7
- [17] NOVOTNÝ, I. *Biologie člověka*, Fortuna Praha, 2003 [ISBN 80-7168-819-3]
- [18] *Optical principle of the simplest form of direct ophthalmoscope*. [online].  
[Cit. 2013-05-07] Dostupné z:  
[http://medical-dictionary.thefreedictionary.com/\\_/viewer.aspx?path=ElMill&name=FOO-02-S2958.jpg](http://medical-dictionary.thefreedictionary.com/_/viewer.aspx?path=ElMill&name=FOO-02-S2958.jpg)
- [19] *Binocular indirect ophthalmoscope*. [online]. [Cit. 2013-05-07] Dostupné z:  
[http://medical-dictionary.thefreedictionary.com/\\_/viewer.aspx?path=ElMill&name=FOO-01-S2958.jpg](http://medical-dictionary.thefreedictionary.com/_/viewer.aspx?path=ElMill&name=FOO-01-S2958.jpg)
- [20] RŮŽEK, V.: *Algoritmy pro rozpoznání ručně psaných znaků*. Zlín: Univerzita Tomáše Bati ve Zlíně, Fakulta aplikované informatiky, 2010, Vedoucí bakalářské práce Ing. Petr Chalupa, Ph.D.

# SEZNAM PŘÍLOH

<b>A</b>	<b>Seznam funkcí Programu</b>	<b>66</b>
<b>B</b>	<b>část zdrojového kódu</b>	<b>70</b>
<b>C</b>	<b>Obsah Přiloženého DVD</b>	<b>73</b>

# A SEZNAM FUNKCÍ PROGRAMU

- Main\_JV.m

```
% *****  
%* Jan Václavík  
%* Hlavní spouštěcí skript modelovacího algoritmu cévního stromu
```

- `function [im2] = ResizeEdit_JV(im)`

```
% *****  
%* Jan Václavík  
%* Úprava obrazu nemocných pacientů  
%* im - vstupní obraz pro úpravu  
%* im2 - výstupní obraz - upravený
```

- `function [imZ,imE] = imgPreProcess_JV(imY)`

```
% *****  
%* Jan Václavík  
%* Předzpracování obrazu, redukce velikosti a určení luminiscenční komponenty  
%* imY - vstupní obraz RGB  
%* imZ - výstupní obraz Gray-Scale  
%* imE - erozní maska
```

- `function [imGF_max] = gaborFilter_JV(imY)`

```
% *****  
%* Jan Václavík  
%* Postupná Gaborova filtrace [0°, 45°, 90°, 135°, 180° ]  
%* imY - vstupní obraz Gray-Scale  
%* imGF_max - výstupní obraz Gray-Scale - filtrovaný
```

- `function [G,gabout] = gaborfilter(I,Sx,Sy,f,theta)`

```
% *****  
%* Ahmad Poursaberi  
%* http://www.mathworks.com/matlabcentral/fileexchange/5237-2d-gabor-filterver123  
%* Gaborova filtrace  
%* I - vstupní obraz Gray-Scale  
%* Sx - směrodatná odchylka v ose x  
%* Sy - směrodatná odchylka v ose y  
%* f - frekvence sinusové funkce  
%* theta - orientace Gaborova filtru  
%* G - výstupní Gaborův filtr  
%* gabout - výstupní obraz Gray-Scale - filtrovaný
```

- **function** [f\_oko1, f\_oko2, f\_oko3] = imgPostProcess\_JV(imGF\_max,imE, per)

```

% *****
%* Jan Václavík
%* Morfologická eroze, prahování a skeletonizace filtrovaného obrazu
%* imGF_max - vstupní obraz Gray-Scale
%* imE - erozní maska
%* per - procentuální hodnota prahu
%* f_oko1 - výstupní obraz Black&White - prahovaný
%* f_oko2 - výstupní obraz Black&White – prahovaný + redukce krátkých úselů
%* f_oko3 - výstupní obraz Black&White – prahovaný + redukce krátkých úselů +
skeletonizace

```

- **function** [bod,first] = ImFind\_JV(imY,a,krok)

```

% *****
%* Jan Václavík
%* Funkce nalezení středu optického disku
%* imY - vstupní obraz Black&White
%* a - velikost hledací masky
%* krok - krok posouvání hledací masky
%* bod - souřadnice středu optického disku
%* first - hustota bodů výsledné hledací masky

```

- **function** [imY] = ImCorrection\_JV(imY,a,krok,hustota,usek)

```

% *****
%* Jan Václavík
%* Funkce pro odstranění bílé plochy obrazu o určité hustotě obrazových bodů
%* imY - vstupní obraz Black&White
%* a - velikost hledací masky
%* krok - krok posouvání hledací masky
%* hustota - prahová hodnota hustoty bílých bodů pro odstranění
%* usek - prahová hodnota počtu spojených bílých bodů pro odstarnění
%* imY - výstupní obraz Black&White – pročištěný

```

- **function** [skalar] = MinFun\_JV(imY,vrchol,parameter,condition,typ,line)

```

% *****
%* Jan Václavík
%* Funkce pro výpočet optimalizační vzdálenost aproximační funkce, s váhováním
%* imY - vstupní obraz Black&White
%* vrchol - souřadnice středu optického disku OD
%* parameter - hlavní parametr aproximační funkce
%* condition - volba mezi singulárním nebo duálním modelováním
%* typ - volba mezi statickým nebo dynamickým modelováním
%* line - volba aproximační funkce
%* skalar - optimalizační vzdálenost

```

- **function** [skalar] = MinFun\_Old\_JV(imY,vrchol,parameter,condition,typ,line)
 

```

% *****
%* Jan Václavík
%* Funkce pro výpočet optimalizační vzdálenost aproximační funkce, bez váhování
%* imY - vstupní obraz Black&White
%* vrchol - souřadnice středu optického disku OD
%* parameter - hlavní parametr aproximační funkce
%* condition - volba mezi singulárním nebo duálním modelováním
%* typ - volba mezi statickým nebo dynamickým modelováním
%* line - volba aproximační funkce
%* skalar - optimalizační vzdálenost

```
- **function** [one] = MezFun\_JV(vzdalenost\_vrchol)
 

```

% *****
%* Jan Václavík
%* Funkce pro vytvoření váhového koeficientu
%* vzdalenost_vrchol - vstupní matice vzdálenosti bodů aproximační funkce od středu optického disku OD
%* one - výstupní omezená matice vzdálenosti bodů aproximační funkce od středu optického disku OD

```
- **function** [xy\_t, xy\_b] = Kvarticka\_JV(siZe,vrchol,parameter,condition,typ)
 

```

% *****
%* Jan Václavík
%* Funkce pro vytvoření modelu kvartické aproximační funkce
%* siZe - velikost modelovaného obrazu
%* vrchol - souřadnice středu optického disku OD
%* parameter - hlavní parametr aproximační funkce
%* condition - volba mezi singulárním nebo duálním modelováním
%* typ - volba mezi statickým nebo dynamickým modelováním
%* xy_t - matice souřadnic horní poloviny aproximační funkce
%* xy_b - matice souřadnic dolní poloviny aproximační funkce

```
- **function** [xy\_t, xy\_b] = Linearni\_JV(siZe,vrchol,parameter,condition,typ)
 

```

% *****
%* Jan Václavík
%* Funkce pro vytvoření modelu lineární aproximační funkce
%* siZe - velikost modelovaného obrazu
%* vrchol - souřadnice středu optického disku OD
%* parameter - hlavní parametr aproximační funkce
%* condition - volba mezi singulárním nebo duálním modelováním
%* typ - volba mezi statickým nebo dynamickým modelováním
%* xy_t - matice souřadnic horní poloviny aproximační funkce
%* xy_b - matice souřadnic dolní poloviny aproximační funkce

```

- `function [xy_t, xy_b] = Parabola_JV(size,vrchol,parameter,condition,typ)`

```

% *****
%* Jan Václavík
%* Funkce pro vytvoření modelu parabolické aproximační funkce
%* size - velikost modelovaného obrazu
%* vrchol - souřadnice středu optického disku OD
%* parameter - hlavní parametr aproximační funkce
%* condition - volba mezi singulárním nebo duálním modelováním
%* typ - volba mezi statickým nebo dynamickým modelováním
%* xy_t - matice souřadnic horní poloviny aproximační funkce
%* xy_b - matice souřadnic dolní poloviny aproximační funkce

```

## B ČÁST ZDROJOVÉHO KÓDU

### VSTUPNÍ APROXIMAČNÍ FUNKCE PRO OPTIMALIZAČNÍ FUNKCI FMINSEARCH

```
function [skalar] = MinFun_JV(imY,vrchol,parameter,condition,typ,line)

size=size(imY);    %velikost obrazu
krok=10;    %krok podvzorkovani bilych bodu v obraze
switch typ switch typ
    case{'dynamic'}    %dynamicky vrchol aproximacni funkce
        vrchol_y=parameter(1);
        vrchol_x=parameter(2);

    case{'static'}    %staticky vrchol aproximacni funkce
        vrchol_y=vrchol(1);
        vrchol_x=vrchol(2);
end
%-----
% Modelovani aproximacnich funkci
%-----
switch line
    case{'par'}
[xy_t, xy_b] = Parabola_JV(size,vrchol,parameter,condition,typ); %vypocet bodu paraboly
    case{'lin'}
[xy_t, xy_b] = Linearni_JV(size,vrchol,parameter,condition,typ); %vypocet bodu usecky
    case{'kva'}
[xy_t, xy_b] = Kvarticka_JV(size,vrchol,parameter,condition,typ); %vypocet bodu
kvadraticke
end
%-----
% Vypocty pro strany paraboly
%-----
switch condition
    case {'both','BOTH','Both'}    %vypocet vzdalenosti pro obe paraboly

    % vybrani jen bilich bodu v HORNÍ polovine obrazu a ulozeni jejich
    % souradnic
    c=1;    % citac bilych bodu v obraze
    for i = 1 : floor((size(1)/2)) % radky, y
        for j = 1: size(2)    % sloupce, x
            if imY(i,j) == 1;
                v_t(1,c)=j;    % x-ova souradnice bileho bodu
                v_t(2,c)=i;    % y-ova souradnice bileho bodu
                c=c+1;
            end
        end
    end
end

% vybrani jen bilich bodu v DOLNÍ polovine obrazu a ulozeni jejich
```

```

% souradnic
c=1; % citac bilych bodu v obraze
for i = ((floor(size(1)/2))+1):size(1) % radky, y
    for j = 1: size(2) % sloupce, x
        if imY(i,j) == 1;
            v_b(1,c)=j; % x-ova souradnice bileho bodu
            v_b(2,c)=i; % y-ova souradnice bileho bodu
            c=c+1;
        end
    end
end

% Podvyorkovani vektoru bilych obrazovych bodu

%%podvyorkovani bilych bodu obrazu k vypoctu vzdalenosti
vektor_t(1,:)=v_t(1,1 : krok : end);
vektor_t(2,:)=v_t(2,1 : krok : end);
vektor_b(1,:)=v_b(1,1 : krok : end);
vektor_b(2,:)=v_b(2,1 : krok : end);

% vzdalenost bodu horniho reciste od horni paraboly
size =size(xy_t);
for i=1:size(2)
    vzdalenost_t(:,i) = sqrt((vektor_t(1,:) - xy_t(1,i)).^2 + (vektor_t(2,:) -
xy_t(2,i)).^2);
end

% vzdalenost bodu dolniho reciste od dolni paraboly
size =size(xy_b);
for i=1:size(2)
    vzdalenost_b(:,i) = sqrt((vektor_b(1,:) - xy_b(1,i)).^2 + (vektor_b(2,:) -
xy_b(2,i)).^2);
end

%vahovani vzdalenosti bodu
vzdalenost_vrchol_t(:,1)= sqrt((xy_t(1,:) - vrchol_x).^2 + (xy_t(2,:) -
vrchol_y).^2);
vaha_t=MezFun_JV(vzdalenost_vrchol_t);
vzdalenost_vrchol_b(:,1) = sqrt((xy_b(1,:) - vrchol_x).^2 + (xy_b(2,:) -
vrchol_y).^2);
vaha_b=MezFun_JV(vzdalenost_vrchol_b);

% suma minimalnich vzdalenosti od jednotlivych bodu
suma(1)=sum((min(vzdalenost_t)).*vaha_t); % vystup MinFun skalar
suma(2)=sum((min(vzdalenost_b)).*vaha_b); % vystup MinFun skalar
skalar = mean(suma); % vystup MinFun skalar
%-----
case {'top','TOP','Top'} %vypocet vzdalenosti horni cast paraboly
% vybrani jen bilych bodu v HORNÍ polovine obrazu a ulozeni jejich
% souradnic
c=1; % citac bilych bodu v obraze
for i = 1 : floor((size(1)/2)) % radky, y
    for j = 1: size(2) % sloupce, x
        if imY(i,j) == 1;
            v_t(1,c)=j; % x-ova souradnice bileho bodu

```

```

        v_t(2,c)=i;      % y-ova souradnice bileho bodu
        c=c+1;
    end
end
end
%%podvyorkovani bilych bodu obrazu k vypoctu vzdalenosti
vektor_t(1,:)=v_t(1,1 : krok : end);
vektor_t(2,:)=v_t(2,1 : krok : end);
% vzdalenost bodu horniho reciste od horni paraboly
size =size(xy_t);
for i=1:size(2)
    vzdalenost_t(:,i) = sqrt((vektor_t(1,:) - xy_t(1,i)).^2 + (vektor_t(2,:) -
xy_t(2,i)).^2);
end
%vahovani vzdalenosti bodu
vzdalenost_vrchol_t(:,1)= sqrt((xy_t(1,:) - vrchol_x).^2 + (xy_t(2,:) -
vrchol_y).^2);
vaha_t=MezFun_JV(vzdalenost_vrchol_t);
skalar=sum((min(vzdalenost_t).*vaha_t)); % vystup MinFun skalar
%-----
case {'bottom','BOTTOM','Bottom'} %vypocet vzdalenosti horni cast paraboly
% vybrani jen bilych bodu v DOLNI polovine obrazu a ulozeni jejich
% souradnic
c=1; % citac bilych bodu v obraze
for i = ((floor(size(1)/2))+1):size(1) % radky, y
    for j = 1: size(2) % sloupce, x
        if imY(i,j) == 1;
            v_b(1,c)=j; % x-ova souradnice bileho bodu
            v_b(2,c)=i; % y-ova souradnice bileho bodu
            c=c+1;
        end
    end
end
%%podvyorkovani bilych bodu obrazu k vypoctu vzdalenosti
vektor_b(1,:)=v_b(1,1 : krok : end);
vektor_b(2,:)=v_b(2,1 : krok : end);
size =size(xy_b);
% vzdalenost bodu dolniho reciste od horni paraboly
for i=1:size(2)
    vzdalenost_b(:,i) = sqrt((vektor_b(1,:) - xy_b(1,i)).^2 + (vektor_b(2,:) -
xy_b(2,i)).^2);
end
%vahovani vzdalenosti bodu
vzdalenost_vrchol_b(:,1) = sqrt((xy_b(1,:) - vrchol_x).^2 + (xy_b(2,:) -
vrchol_y).^2);
vaha_b=MezFun_JV(vzdalenost_vrchol_b);
skalar=sum((min(vzdalenost_b).*vaha_b)); % vystup MinFun skalar

otherwise
    warning('Neni zvolena cast paraboly ktera se ma minimalizovat');
end

```

*[Published with MATLAB® R2012b](#)*

## C OBSAH PŘILOŽENÉHO DVD

### Program

- Soubor testovacích dat - Nemocné a zdravé testovací snímky sítnice
- Výsledky - Složka pro ukládání výsledků Modelovacího programu s excelovskými skripty pro výpočty statistických hodnot
- Výsledky modelování – Zde jsou uloženy všechny výsledky Modelovacího programu
- Jednotlivé funkce Modelovacího programu

### Text

- Elektronická verze Diplomové práce PDF