


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 CÉVNÍHO ŘEČIŠTĚ NA SNÍMCÍCH SÍTNICE S VYUŽITÍM MATEMATICKÉ MORFOLOGIE

BLOOD VESSEL SEGMENTATION IN FUNDUS IMAGES USING MATHEMATICAL
MORPHOLOGY

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR


STANISLAV STONAWSKI

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. JAN ODSTRČILÍK

BRNO 2013



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Bakalářská práce

bakalářský studijní obor

Biomedicínská technika a bioinformatika

Student: Stanislav Stonawski

ID: 136183

Ročník: 3

Akademický rok: 2012/2013

NÁZEV TÉMATU:

Segmentace cévního řečiště na snímcích sítnice s využitím matematické morfologie

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s principem snímání očního pozadí pomocí fundus kamery a s vlastnostmi takto získaných obrazových dat. Přednostně se zaměřte na vlastnosti cévního řečiště. 2) Provedte rešerši dostupné literatury z oblasti segmentace cévních struktur na snímcích sítnice a zaměřte se zejména na metody využívající matematické morfologie. 3) Dle pokynů vedoucího vybraný přístup implementujte v libovolném programovém prostředí. 4) Vytvořenou metodu otestujte na dostupných obrazových datech a vyhodnoťte její účinnost. 5) Provedte diskusi výsledků a zhodnoťte využitelnost aplikovaného řešení. 6) K vytvořeným programovým funkcím sepište přehledný návod k obsluze.

DOPORUČENÁ LITERATURA:

[1] ODSTRČILÍK, Jan, et al. Improvement of Vessel Segmentation by Matched Filtering in Colour Retinal Images. IFMBE Proceedings, vol. 25, pp. 327-330, 2009.

[2] ZANA, Frédéric, et al. Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation. IEEE Trans. Image Proc., vol. 10, no. 7, pp. 1010–1019, 2001.

Termín zadání: 11.2.2013

Termín odevzdání: 31.5.2013

Vedoucí práce: Ing. Jan Odstrčilík

Konzultanti bakalářské práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské 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

Důležitým krokem analýzy sítnicových snímků je segmentace cévního řečiště. Výsledek této analýzy může být využit při diagnostice očních či kardiovaskulárních onemocnění. Tato práce se zabývá možnostmi segmentace cévního řečiště ve snímcích s vysokým rozlišením za využití metod matematické morfologie. Cílem práce je vytvoření algoritmu, který bude schopen segmentace cévního řečiště ze sítnicových snímků. Dalším cílem je provedení hodnocení jeho účinnosti. Práce se stručně zabývá problematikou fundus kamer, vlastnostmi jejich obrazových dat a databází snímků. Dále jsou popsány vlastnosti cévního řečiště v těchto snímcích společně se způsoby jeho segmentace. Prezentovány jsou vytvořené algoritmy a výsledky jejich aplikace na databázi High-Resolution Fundus Image Database.

KLÍČOVÁ SLOVA

Matematická morfologie, cévní řečiště, snímky sítnice, morfologická filtrace, segmentace

ABSTRACT

Segmentation of retinal blood vessel is an important step in the fundus image analysis. The resulting image can be used to diagnose ophthalmic or cardiovascular diseases. The aim of this thesis is to search for possibilities of high resolution eye fundus image processing while using mathematical morphology methods. This should lead to the creation of an algorithm capable of blood vessel segmentation. The thesis provides information on fundus camera, image, blood vessel properties and mathematical morphology filtering methods. The created algorithms and the proposed method based on them are presented, including their performance analysis based on the HRF database processing.

KEYWORDS

Mathematical morphology, blood vessel, retinal images, morphological filtering, segmentation

STONAWSKI, S. *Segmentace cévního řečiště na snímcích sítnice s využitím matematické morfologie*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2013. 53 s. Vedoucí bakalářské práce Ing. Jan Odstrčilík.

PROHLÁŠENÍ

Prohlašuji, že svoji bakalářskou práci na téma Segmentace cévního řečiště na snímcích sítnice s využitím matematické morfologie jsem vypracoval samostatně pod vedením vedoucího bakalářské 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 bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si 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. 40/2009Sb.

V Brně dne

.....

(podpis autora)

PODĚKOVÁNÍ

Děkuji vedoucímu bakalářské práce ing. Janu Odstrčilíkovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně dne

.....

(podpis autora)

OBSAH

Obsah	vi
Seznam obrázků	ix
Seznam tabulek	xi
Úvod	1
1 Fundus kamera	3
1.1 Základní princip	3
1.2 Canon Fundus Camera CF-60Uvi.....	4
2 Snímky sítnice	6
2.1 Databáze snímků sítnice	6
2.1.1 Databáze DRIVE	6
2.1.2 Projekt STARE	7
2.1.3 High-Resolution Fundus Image Database (HRF).....	8
2.2 Vlastnosti cévního řečiště ve snímcích sítnice	10
3 Segmentace cévního řečiště	12
3.1 Užívané metody segmentace cévního řečiště	12
3.2 Metody morfologické filtrace cévního řečiště	13
4 Metody matematické morfologie	17
4.1 Základní morfologické operátory a práce s nimi v prostředí MATLAB	17
5 Navržené filtrační a segmentační techniky	19
5.1 Realizace	19
5.2 Morfologické operace	19
5.2.1 Otevření lineárním SE definovatelné délky	19
5.2.2 Uzavření lineárním SE definovatelné délky	20

5.2.3	Top-hat transformace lineárním rotujícím SE definovatelné délky....	21
5.2.4	Bottom-hat transformace rotujícím SE definovatelné délky	22
5.2.5	Morfologické zvýraznění obrazu	23
5.2.6	Modifikovaná víceúrovňová top-hat transformace.....	24
5.2.7	Dvouprahová morfologická binární rekonstrukce (dvouprahový operátor)	24
5.3	Nemorfologické operace.....	25
5.3.1	DooG filtrace	25
5.3.2	Obraz na základě vlastních čísel Hessianovy matice	27
5.3.3	Dělení bitové palety a bitová rekonstrukce.....	27
5.4	Pomocné funkce.....	30
5.4.1	Hodnocení snímků	30
5.4.2	Přepočet obrazových hodnot.....	30
6	Navržená metoda	31
6.1	Předzpracování obrazu.....	32
6.1.1	Aplikace morfologického otevření	32
6.1.2	Morfologická rekonstrukce.....	33
6.1.3	Morfologické zvýraznění obrazu	33
6.2	Morfologická top-hat transformace a rekonstrukce.....	34
6.2.1	Víceúrovňová modifikovaná top-hat transformace a dvouprahový operátor	34
6.3	Získání profilů cév pomocí vlastních čísel Hessianovy matice.....	38
6.3.1	Tvorba obrazu profilů cév z vlastních čísel Hessianovy matice.....	38
6.4	Získání výsledků	41
7	Zhodnocení dosažených výsledků	42
7.1	Hodnocení navrženého algoritmu	42
7.1.1	Dosažené výsledky	42
7.1.2	Diskuze výsledků	44

7.1.3	Hodnocení algoritmu	46
7.2	Postupy nevyužité v navržené metodě.....	47
7.2.1	DooG filtrace	47
7.2.2	Dělení bitové palety a bitová rekonstrukce.....	48
8	Závěr	49
	Literatura	50

SEZNAM OBRÁZKŮ

Obrázek 1.1: Schéma retinální kamery: 1) zobrazovací jednotka; 2,3,4) poziční jednotka; 5) operační panel pro lékaře; 6) objektiv; 7) PC; převzato z [15]:	4
Obrázek 1.2: Canon Fundus Camera CF-60UVi; převzato z [9]:	5
Obrázek 2.1: Příklad snímku z databáze DRIVE (vlevo) a ručně vytvořený zlatý standard tohoto snímku (vpravo); převzato z [10]:	7
Obrázek 2.2: Příklad snímku z databáze projektu STARE se dvěma manuálními segmentacemi; převzato z [11]	8
Obrázek 2.3: Vzorový snímek z databáze HRF; převzato z [12]	8
Obrázek 2.4: Maska (vlevo) a manuálně segmentovaný zlatý standard (vpravo) z databáze HRF; převzato z [12]:	9
Obrázek 2.5: Červený kanál RGB kódovaného obrazu	10
Obrázek 2.6: Zelený kanál RGB kódovaného obrazu	10
Obrázek 2.7: Modrý kanál RGB kódovaného obrazu	10
Obrázek 5.1: Výsledek lineárního uzavření zeleného kanálu pomocí SE délky 37 pixelů ve 45 orientacích	21
Obrázek 5.2: Výsledek top-hat transformace (obrazu po aplikaci lineárního otevření a rekonstrukci) s lineárním SE délky 37 pixelů ve 45 orientacích (při aplikaci na negativ původního obrazu totožné s bottom-hat; obrázek upraven v Adobe PS pro lepší vypovídací hodnotu)	22
Obrázek 5.3: Výsledek bottom-hat transformace (obrazu po aplikaci lineárního otevření a rekonstrukci) s lineárním SE délky 37 pixelů ve 45 orientacích (obrázek upraven v Adobe PS pro lepší vypovídací hodnotu)	23
Obrázek 5.4: Jedna z šesti směrových orientací DooG filtru, převzato z [4]	25
Obrázek 5.5: Výsledek jedné směrové orientace DooG filtrace po aplikaci MM otevření	26
Obrázek 5.6: Výsledek složení všech směrových orientací DooG filtrace (segmentace pomocí <i>Dvouprahová morfologická binární rekonstrukce (dvouprahový operátor)</i>)	26

Obrázek 5.7: Hessova matice pro každý obrazový bod reprezentující jeho vlastnosti v tomto bodě; převzato z [18]	27
Obrázek 5.8: Informace uložená v bitech 1-4.....	28
Obrázek 5.9: Informace uložená v bitech 5-8.....	29
Obrázek 5.10: Výsledek bitové rekonstrukce (informace z bitů 5 a 6)	29
Obrázek 6.1: Blokové schéma navržené metody.....	31
Obrázek 6.2: Výsledek lineárního otevření obrazu zeleného kanálu pomocí SE délky 37 pixelů ve 45 orientacích	32
Obrázek 6.3: Výsledek morfologické rekonstrukce otevřeného obrazu dle původního obrazu zeleného kanálu.....	33
Obrázek 6.4: Výsledek morfologického zvýraznění obrazu.....	34
Obrázek 6.5: Výsledek modifikované top-hat transformace (rekonstruovaného obrazu) s cirkulárním SE (průměr obrazů s užitím SE o průměrech 5 a 9 pixelů) ...	35
Obrázek 6.6: Výsledek modifikované top-hat transformace (rekonstruovaného obrazu) s cirkulárním SE (průměr obrazů s užitím SE o průměrech 13 a 17 pixelů)...	35
Obrázek 6.7: Výsledek modifikované top-hat transformace (rekonstruovaného obrazu) s cirkulárním SE (průměr obrazů s užitím SE o průměrech 21 a 25 pixelů) ...	36
Obrázek 6.8: Výsledek dvouprahového operátoru pro první obraz získaný pomocí Víceúrovňová modifikovaná top-hat transformace	37
Obrázek 6.9: Výsledek dvouprahového operátoru pro druhý obraz získaný pomocí <i>Víceúrovňová modifikovaná top-hat transformace</i>	37
Obrázek 6.10: Výsledek dvouprahového operátoru pro třetí obraz získaný pomocí <i>Víceúrovňová modifikovaná top-hat transformace</i>	38
Obrázek 6.11: Obraz získaný z vlastních čísel Hessovy matice na úrovni $\sigma=7$	39
Obrázek 6.12: Obraz získaný z vlastních čísel Hessovy matice na úrovni $\sigma=\sqrt{8}$	39
Obrázek 6.13: Výsledný obraz získaný z vlastních čísel Hessovy matice na úrovni $\sigma=7$ po prahování a <i>postprocessing</i> úpravách	40
Obrázek 6.14: Výsledný obraz získaný z vlastních čísel Hessovy matice na úrovni $\sigma=\sqrt{8}$ po prahování a <i>postprocessing</i> úpravách	40
Obrázek 6.15: Výsledný obraz segmentovaného cévního řečiště.....	41
Obrázek 7.1: Obraz s nejhorší celkovou úrovní klasifikace	44

SEZNAM TABULEK

Tabulka 1.1: Parametry fundus kamery CF-60UVi; převzato z [9]	5
Tabulka 7.1: Vyhodnocení účinnosti algoritmu na skupině obrázků DR z HRF databáze	42
Tabulka 7.2: Vyhodnocení účinnosti algoritmu na skupině obrázků G z HRF databáze	43
Tabulka 7.3: Vyhodnocení účinnosti algoritmu na skupině obrázků H z HRF databáze	43
Tabulka 7.4: Průměrné hodnoty dosažených výsledku předešlých prací zabývajících se tímto tématem (výsledky pro databázi DRIVE)	45
Tabulka 7.5: Průměrné hodnoty dosažených výsledku předešlých prací zabývajících se tímto tématem (výsledky pro databázi STARE).....	45
Tabulka 7.6: Vyhodnocení algoritmu na skupině obrázků DR z HRF databáze dle [22]	45
Tabulka 7.7: Vyhodnocení algoritmu na skupině obrázků G z HRF databáze dle [22].	45
Tabulka 7.8: Vyhodnocení algoritmu na skupině obrázků H z HRF databáze dle [22].	46
Tabulka 7.9: Vyhodnocení účinnosti starší iterace algoritmu na skupině obrázků DR z HRF databáze	46
Tabulka 7.10: Vyhodnocení účinnosti starší iterace algoritmu na skupině obrázků G z HRF databáze	46
Tabulka 7.11: Vyhodnocení účinnosti starší iterace algoritmu na skupině obrázků H z HRF databáze	47
Tabulka 7.12: Výsledek vyhodnocení <i>Obrázek 5.6</i> pomocí dvouprahového operátoru (obraz 12_h).....	48
Tabulka 7.13: Výsledek vyhodnocení <i>Obrázek 5.10</i> (obraz 12_h)	48

ÚVOD

V oftalmologické praxi patří vyšetření očního pozadí mezi základní úkony. Informace získané tímto vyšetřením jsou schopny pomoci při diagnostice některých očních či kardiovaskulárních onemocnění [12], [15].

Moderní technologie dovolují kromě přímého pozorování očního pozadí i snímání dat nesoucích v sobě informaci o jeho struktuře. Mezi dnes běžně užívané zařízení se řadí fundus kamera, která je schopná vytvořit fotografii očního pozadí dostatečně kvalitní i pro diagnostické účely.

Blíže se problematikou fundus kamery zabývá kapitola 1.

Při pohledu na takovou fotografii lze rozlišit několik významných struktur. Pozadí celého snímku tvoří sítnice (*retina*), která je v zorném poli (*Field of View - FoV*) fundus kamery tvořena fotoreceptory tyčinkami a čípky, dále vrstvami buněk bipolárních, horizontálních, amakrinních a gangliových. Asi nejvýraznějším prvkem na tomto pozadí je tzv. slepá skvrna, což je místo, které je společným vstupem axonů a cévního řečiště do oka. Toto místo je také nazýváno optický disk. Zevně od optického disku leží žlutá skvrna (*macula lutea*), v jejímž centru je největší koncentrace čípků z celé sítnice zajišťující ostré *fotopické* vidění. Cirkulárně kolem žluté skvrny leží místa s nejvyšším podílem tyčinek, kde je nejostřejší vidění *skotopické* [17].

Mezi choroby projevující se změnami tohoto obrazu můžeme zařadit například diabetickou retinopatii nebo glaukom (zelený zákal) [12], [15].

Zpracování retinálních snímků má v dnešní době potenciál být převážně automatizovaným. Existuje velké množství metod analýzy, segmentace i diagnostiky jednotlivých příznaků mající různě úspěšné výsledky. Snahou je sestavení sekvencí co nejrobustnějších metod umožňujících komplexní vyhodnocovací proces, jehož výsledkem by bylo dostatečně přesné a plně automatické zpracovávání získaných dat pro užití v klinické praxi.

Tématem této bakalářské práce je segmentace cévního řečiště na snímcích sítnice s využitím matematické morfologie (MM). Existuje řada vědeckých prací zabývajících se tímto tématem [1], [2], [3], [4], [18], [19], [20]. Je také několikero přístupných databází retinálních snímků [10], [11], [12], které jsou podporou pro podobná snažení.

Vlastnosti cévního řečiště ve snímcích fundus kamery jsou popsány v kapitole 2. jednotlivé způsoby segmentace cévního řečiště přiblíženy v kapitole 3.

Tato bakalářská práce si především klade za cíl vyvinutí prakticky využitelných filtračních postupů (se zaměřením na metody MM), jejichž výsledkem bude skupina příznaků, které budou zapojeny do procesu klasifikace cévních struktur očního pozadí. Dále také vytvoření segmentačního algoritmu užívajícího tyto postupy, včetně vyhodnocení jeho výsledků po aplikaci na databázi High-Resolution Fundus Image Database (HRF) [12].

Informace o metodách užívaných v této práci jsou obsaženy v kapitole 4, 5 a 6. Zhodnocení algoritmu a dosažených výsledků se věnuje kapitola 7.

1 FUNDUS KAMERA


Fundus kamera je oftalmologický přístroj sloužící k fotografování očního pozadí. Získané snímky mohou být užity jak pro dokumentaci, tak i diagnostiku (nejen) očních chorob. Na těchto snímcích je mimo jiné možno neinvazivně pozorovat cévní řečiště sítnice, což není na jiném místě těla proveditelné [15].

1.1 Základní princip

Základem fundus kamery je specializovaný nízkoenergetický mikroskop s integrovaným fotoaparátem. V dnešní době se jedná o digitální fundus kamery zaznamenávající obraz pomocí CCD, modernější přístroje dovolují snímání nejen klasické 2D fotografie, ale i 3D stereofotografie [15], [16].

Dle principu funkce existují tři základní druhy fundus kamer. Mydriatické fundus kamery vyžadují před snímáním podání mydriatik pacientovi, ty se aplikují do oka ve formě kapek a slouží k rozšíření zornice. Nemydriatické kamery jsou konstruovány tak, aby tohoto kroku nebylo potřeba. Posledním typem jsou fundus kamery pro dvojí užití (*dual-use*), které v sobě kombinují možnosti obou předešlých zařízení [14].

Design a technické provedení kamer se s postupem technologií a dle výrobců samozřejmě mění, dříve byly například užívány kamery se třemi samostatnými optickými systémy, pozorovacím, fotografickým (snímacím) a osvětlovacím, zatímco dnes je možné se setkat s kamerami, jejichž provedení umožňuje spojení některých těchto optických systémů [14].



Obrázek 1.1: Schéma retinální kamery:1) zobrazovací jednotka;2,3,4) poziční jednotka; 5)operační panel pro lékaře; 6) objektiv; 7) PC; převzato z [15]:

1.2 Canon Fundus Camera CF-60Uvi

Všechny snímky zpracováváné v této práci jsou získány pomocí CANON fundus kamery CF-60Uvi s vestavěným fotoaparátem CANON EOS-20D.

Vlastnosti kamery jsou následující (převzato z [9]):

- FoV 30°, 40°, 60°,
- přesný zaostřovací systém,
- nastavení pracovní vzdálenosti,
- automatická expozice na 35mm barevné fotografie,
- automatické natáčení,
- volitelně snímání s červeným a modrozeleným filtrem,
- možnost fluorescenční a indocyanínové angiografie (s automatickým nastavováním filtrů),
- režim snímání při úzké zornici,
- vestavěný fotoaparát CANON EOS-20D s 8,2 Mpix CMOS snímačem,
- možnost tisku snímků.



Obrázek 1.2: Canon Fundus Camera CF-60UVi; převzato z [9]

Tabulka 1.1: Parametry fundus kamery CF-60UVi; převzato z [9]

FoV	60°, 40°, 30° 60°, 40°, 30°
Zvětšení u 35 mm filmu	1.7x (60°), 2.5x (40°), 3.4x (30°)
Velikost snímků	ø29 mm ´ 22 mm (35 mm film) ø75 mm ´ 57 mm (Polaroid film)
Minimální průměr čočky	ø4 mm
Pracovní vzdálenost	45 mm
Rozsah dioptrií	-10 to +12D (bez kompenzační čočky) -6 to -27D (záporná kompenzační čočka) +9 to +32D (kladná kompenzační čočka)
Nastavení dioptrií obsluhy	± 5D
Zdroj bílého světla	300 W xenonová výbojka
Možnosti natáčení	Vertikálně: 38 mm Dopředu/dozadu: 70 mm Vpravo/vlevo: 120 mm Pohyb tváře: 65 mm
Rozměry	320 mm x 560 mm x 565 mm
Váha	26 kg

2 SNÍMKY SÍTNICE

Existuje několik databází, které shromažďují retinální snímky. V následujícím textu budou popsány nejvýznamnější z nich. Jejich společným rysem je volný přístup k obsaženým datům pro výzkumné a výukové účely. Tyto databáze obsahují snímky vzniklé v rozdílných kontextech za pomoci různých zařízení, čímž je dána nesourodost jejich parametrů. Nejvýznamnějšími jsou pro nás Databáze Drive [10], databáze Projektu STARE [11] a databáze HRF [12].

Není opomenuta ani část dat, která nás v této práci zajímá nejvíce, a to vlastnosti samotného cévního řečiště. Jako výsledek zkoumání těchto vlastností byl formulován matematický model, ze kterého se vychází při tvorbě a stanovení parametrů některých segmentačních metod.

Metody segmentace s užitím MM v minulosti byly aplikovány převážně na snímky z databází DRIVE a STARE s mnohem nižším rozlišením, než je v databázi HRF, což výrazně znesnadňovalo přesnou lokalizaci cévních struktur, především tenkých kapilár.


2.1 Databáze snímků sítnice

2.1.1 Databáze DRIVE

Tato databáze [10] byla založena pro umožnění komparativních studií metod segmentace sítnicových obrazů, testování algoritmů a sdílení výsledků s dalšími výzkumníky v oboru.

Fotografie pro tuto databázi byly získány během screeningového programu diabetické retinopatie v Nizozemsku. Programu se účastnilo 400 diabetických pacientů ve věkovém rozmezí 25-90 let. Náhodně bylo vybráno 40 fotografií, 33 z nich neunesou známky diabetické retinopatie a 7 poukazuje na mírně pokročilé stadium tohoto onemocnění. Tyto snímky tvoří databázi DRIVE.

Data byla získána s užitím CANON CR5 nemydriatické 3CCD kamery s 45° FoV. Každý snímek má rozlišení 565*584 pixelů, 72 ppi, je k němu přiložena maska vymezující jeho FoV a zlatý standard. Snímky jsou k dispozici ve formátu TIF s 8 bitovou barevnou hloubkou na kanál v RGB kódování. Masky a zlaté standardy mají formát GIF.



Obrázek 2.1: Příklad snímku z databáze DRIVE (vlevo) a ručně vytvořený zlatý standard tohoto snímku (vpravo); převzato z [10]

Data jsou rozdělena na 2 sady, tréninkový a testovací. Oba obsahují 20 snímků. V tréninkovém setu je k dispozici jeden manuálně segmentovaný zlatý standard cévního řečiště, testovací set obsahuje dvě verze těchto manuálních segmentací. Segmentace zlatých standardů prováděli nezávislí a trénovaní oftalmologové s instrukcemi označit všechny pixely, které považovali za cévní řečiště alespoň na 70 procent.

2.1.2 Projekt STARE


Tento projekt [11] se zabývá možností vytvoření systému automatické analýzy a diagnostiky lidského oka a jeho onemocnění s využitím snímků očního pozadí. Snahou je vytvořit systém, který by svou funkcí napodoboval lékaře v procesu analýzy, předložení nálezu a následné diagnózy. Tomu by se dělo na dvou úrovních, první z nich tvoří automatické zpracování obrazů pro vytvoření základního nálezu, druhý sestává z rozboru získaných dat za účelem vyvození diagnózy.

Databáze obsahuje 402 snímků, mimo dvou typů standardů obsahuje detailní rozměření anatomických struktur sítnicových obrazů, což je užitečné pro sledování časové progresy onemocnění.

Snímky jsou uloženy ve formátu PPM v rozlišení 700*605 pixelů, 72 ppi, s 8 bitovou barevnou hloubkou na kanál RGB kódování.

Snímány jsou s FoV 60° pro panoramatický snímek a 10° pro detaily [23].

Do budoucna se nevyklučuje možnost rozšiřování databáze či podpora kliniků s užitím databáze pro výukové a tréninkové účely.




Obrázek 2.2: Příklad snímku z databáze projektu STARE se dvěma manuálními segmentacemi; převzato z [11]

2.1.3 High-Resolution Fundus Image Database (HRF)

Všechny snímky zpracovávané v této práci pochází z databáze HRF [12], která vznikla za účelem podpory podobných snažení. V době jejího vzniku nebyl snadný přístup ke snímkům očního pozadí s vysokým rozlišením a zároveň jejich zlatým standardům. Založení takovéto databáze tedy usnadňuje jak vývoj nových postupů pro (nejen) segmentaci cévního řečiště, tak také hodnocení těchto metod.

Databáze obsahuje 15 snímků z každé kategorie pacientů, a to zdravých pacientů (H), pacientů s diabetickou retinopatií (DR) a s glaukomem (G).




Obrázek 2.3: Vzorový snímek z databáze HRF; převzato z [12]

Všechny fotografie jsou pořízeny s pomocí CANON Fundus Camera CF-6UVi (mydriatická) s vestavěným fotoaparátem CANON EOS-20D. Ke každé fotografii je k dispozici binární zlatý standard a maska vytyčující její zorné pole, obojí ve formátu TIF.

Rozlišení fotografií je 3504*2336 pixelů, 72 ppi, snímány jsou s užitím FoV 60° a uloženy ve formátu JPEG s nízkou kompresí v RGB kódování s 8 bitovou barevnou hloubkou na kanál.

Zlaté standardy byly manuálně vytvořeny skupinou odborníků v oblasti analýzy sítnicových snímků a pracovníky oftalmologických klinik.




Obrázek 2.4: Maska (vlevo) a manuálně segmentovaný zlatý standard (vpravo) z databáze HRF; převzato z [12]


Díky velkému rozlišení (přes 8 Mpx) je databáze vhodná pro testování přesnosti vytvořených algoritmů

2.2 Vlastnosti cévního řečiště ve snímcích sítnice


Při rozložení retinálního snímku na jednotlivé RGB kanály zjistíme, že největší množství užitečných informací o cévním řečišti se nalézá v jeho zelené složce.



Obrázek 2.5: Červený kanál RGB kódovaného obrazu



Obrázek 2.6: Zelený kanál RGB kódovaného obrazu



Obrázek 2.7: Modrý kanál RGB kódovaného obrazu

V této složce se cévy jeví jako tmavé po částech lineární spojitě struktury vycházející z optického disku, postupně vidlicovitě dělicí a zužující se směrem od něj. Pokud vezmeme v potaz sekční řez cévou, jeho profil intenzit nabývá Gaussovského charakteru [1].

Nejtlustší cévy v databázi HRF dosahují šíře kolem 36 pixelů. Některé z nich mohou mít ve své středové linii centrální reflex, světlý proužek, který znesnadňuje proces filtrace a segmentace.

V [1] jsou mimo jiné definovány struktury negativním způsobem ovlivňující proces segmentace cévního řečiště:

- šum vzniklý při procesu digitalizace či součásti obrazu, jejichž textura má charakter bílého šumu nízké intenzity,
- lineární struktury pozadí mající zdánlivě vlastnosti cév (nemají všechny jejich vlastnosti),
- další druhy vzorů nelineárních, ale kolidujících s některými parametry užitými pro hodnocení:
 - o rozsáhlé světlé či tmavé oblasti,
 - o úzké světlé či tmavé nepravidelné oblasti,
 - o malé světlé či tmavé nepravidelné oblasti,
- obecně špatný poměr signálu vůči šumu.

3 SEGMENTACE CÉVNÍHO ŘEČIŠTĚ

První část této kapitoly obsahuje obecné poznatky o užívaných metodách segmentace cévního řečiště sítnice, druhá část se věnuje konkrétně metodám užívajícím do jisté míry metody matematické morfologie.

V procesu úpravy obrazů za účelem segmentace retinálního cévního řečiště se nejčastěji užívají hybridní algoritmy, což jsou kombinace několika metod. V téměř všech případech se vyskytují tři hlavní kroky charakterizující postup, těmito kroky jsou *pixel preprocessing* (odstranění šumu, zesílení užitečného signálu v obraze), filtrace (výběr příznaků - kandidátů na cévní řečiště) a extrakce pozitivních kandidátů z obrazu.

3.1 Užívané metody segmentace cévního řečiště

Tyto metody můžeme obecně rozdělit do několika hlavních kategorií dle způsobu přístupu k problému. Tyto přístupy mohou být následující.

- Filtrační

Zpracovávání pixelů v masce dané velikosti vymezující okolí pixelu, postupně procházejícím obraz jeden pixel po druhém. Okolí pixelu může být zpracováváno s přihlédnutím k určitému předem určenému a očekávanému modelu (matematicko morfologický popis cévního řečiště). Tato metoda je například užita v [5], kde jsou vytvořeny přizpůsobené filtry dle očekávaných cévních vlastností, následně je provedena konvoluce těchto filtrů s retinálním obrazem.

Mezi tyto metody lze zařadit i matematickou morfologii [1],[2],[3],[4],[18],[19],[20],[21],[22] či víceúrovňovou analýzu [7], [21].

- Klasifikační metody

Dle parametrů získaných z dat a zlatých standardů dojde k rozdělení pixelů do skupin náležících/nenáležících cévnímu řečišti za pomoci klasifikátorů, například neuronových sítí, které byly naučeny tyto skupiny rozeznávat [8].

- Stopovací metody

V těchto metodách je společným principem zadání menší skupiny počátečních bodů, ze kterých algoritmus vychází, dochází k postupnému prohledávání okolních pixelů pro identifikaci těch, které nejlépe odpovídají modelu cévního řečiště

(bere se na zřetel intenzita či tvar profilu sekčního řezu cévou), postupně je vytvářena „cesta“ tvořící segmentované cévní řečiště [6].

3.2 Metody morfologické filtrace cévního řečiště

V [1] je prováděna segmentace cévního řečiště za pomoci matematické morfologie a hodnocení sekčních profilů cév vycházející z vlastností modelu cévních struktur. Algoritmus sestává ze čtyř částí, a to redukce šumu, zvýraznění lineárních vzorů, hodnocení sekčních řezů s Gaussovským profilem a lineární filtrace.

Snímky byly v tomto případě snímány po injekci fluorescenční látky, cévní struktury se tedy jeví v obraze jako vzory s vysokou intenzitou.

Díky znalostem základních vlastností cévních struktur v retinálním obraze, linearitě, spojitosti a tvaru sekčních řezů, bylo rozhodnuto ke zvýraznění těchto struktur využit morfologické filtry s lineárním strukturním elementem (SE).

Postup dle užitých vlastností:

1. Rozpoznání lineárních částí

Provedeno s užitím morfologického otevření obrazu s lineárním strukturním elementem orientovaným ve 12 směrech. Suma top-hat takto upraveného obrazu (se stejným počtem strukturních elementů totožných vlastností jako při otevření) tvoří zvýrazněné cévní řečiště, ovšem se spoustou šumu a nezachovalými větveními cév. Proto je operace upravena následovně.

2. Odstranění nechtěných prvků obrazu s užitím další vlastnosti-spojivosti

Tohoto efektu je docíleno upravením původního otevření na lineární otevření rekonstrukcí dle původního obrazu. Suma top-hat takového obrazu zvýrazní cévy ve všech směrech v závislosti na velikost úhlu, který tvoří rozdíl orientací jednotlivých SE. I po této operaci však obraz obsahuje některé nechtěné prvky.

3. Užití diferenciálních vlastností k hodnocení zakřivení sekčních řezů cév

V tomto stadiu má každý nenulový bod v obraze dominantní směr a lze jej považovat za součást prodlouženého vzoru, jehož sekční řez může být testován pro identifikaci vlastností cévního profilu. Hodnocení zakřivení je provedeno za pomoci Laplaceanu Gausiánu.

Následuje set operací pro odstranění dalšího nechtěného šumu. Lineární otevření rekonstrukcí, lineární uzavření rekonstrukcí a finální obraz je vzat jako pixely větší nebo rovny 1 po umocnění otevření na druhou.

Metoda [2] popisuje postup ne nepodobný předešle popisovanému. Opět se jedná o zvýrazňování cévních struktur pomocí lineárních SE, s rozdílem ve vlastnostech samotných SE (o 3 pixely kratší) a také obrazu (tentokrát je užita zelená složka RGB obrazu).

Je zde poukázáno na nedostatky metody, kdy se přese všechno snažení nelze vyhnout občasnému chybění vidlicovitých dvojení cév, stejně jako rušivému centrálnímu reflexu ve středech cév.

Tato metoda se snaží o napravení chyb předešlé utilizací morfologické binární rekonstrukce. Je užito dynamické lokální narůstání okolí binárního obrazu prahovaného výsledku z doposud provedených operací. Ten je porovnán s původním obrazem (jeho zelenou složkou). Jsou určeny hrany segmentovaných binárních obrazů cév. Pixely ležící v osmi směrech kolem pixelů hranic cév jsou označeny za možná růstová centra rekonstrukce, která jsou vzata do procesu rekonstrukce v závislosti na jejich homogenitě intenzity v porovnání s pixely cév nalézajícími se v blízkosti těchto bodů. Nad každým kandidátem je umístěno okno, ve kterém se počítají požadované parametry. Jsou stanoveny podmínky, které musí být splněny pro označení kandidáta za součást řečiště. Problém však tvoří zašumělé regiony.

Metoda segmentace [3] je založená na kombinaci MM a STFT analýzy (Short Time Fourier Transform). Na rozdíl od [1], stejně jako ve [2], se pracuje se zelenou složkou RGB obrazu.

MM je použita pro zvýraznění cévního stromu, STFT slouží k odstranění nechtěných složek obrazu a k finální segmentaci.

Nejdříve je aplikován Gaussovský filtr následovaný otevřením s použitím SE tvaru diamantu. Gaussovský filtr vyhladí obraz a odstraní malé nepotřebné detaily, následující otevření odstraňuje všechna maxima menší než SE. Cévy jsou v tomto případě tmavé, takže nejsou tímto filtrem ovlivněny (pokud jeho velikost nepřesahuje šířku nejmenších cév). To zapříčiňuje redukci detailů, které nejsou předpokládanými cévami.

Po této úpravě následuje toggle mapping transformace popsaná jako:

- uzavření obrazu v případě, že hodnoty bottom-hat původního obrazu jsou menší nebo rovny velikosti top-hat původního obrazu,
- v opačném případě provedené otevření.

Tato transformace ústí ve zvýšení kontrastu a zvýraznění hran.

Toggle mapping následuje bottom-hat transformace, na kterou je aplikováno otevření s lineárním SE v 18 směrech pro odstranění nechtěných vzorů. Tento obraz se dále upravuje užitím morfologické rekonstrukce. Její výsledek je užit pro další analýzu pomocí STFT.

V dalším článku [4] jsou na retinální obraz nejdříve aplikovány některé postupy nenáležící MM, například DooG (Difference of offset Gaussian) filtry. Ty využívají vlastnosti sekčního profilu cévy, konkrétně opačného znaménka derivace na každé straně tohoto profilu. Je navrženo několik směrově orientovaných filtrů přizpůsobených orientacím cév pro výpočet lokálního gradientu v obraze, pozice pixelů s nejvyšší intenzitou se dají považovat za kandidáty cévního řečiště, vhodnou klasifikační metodou lze z obrazů tyto pixely extrahovat a složit kostru cévního řečiště.

První z operací založených na MM je využití modifikované víceúrovňové top-hat transformace aplikované na obraz s normalizovaným pozadím získaný předešlými nemorfologickými postupy. Modifikace spočívá v uzavření obrazu následovaném jeho otevřením, teprve poté jsou odečteny hodnoty získaného obrazu od původního. To vše probíhá na několika úrovních. Uzavření užívá malý SE konstantní velikosti, pro otevření je užit SE postupně se zvětšující pro pokrytí celého rozmezí šířky cév v obraze (8 různých průměrů). Z těchto 8 obrazů jsou zprůměrováním získány 4 snímky se zlepšeným poměrem signál/šum obsahující postupně filtrované různé části cévního řečiště.

Ty jsou dále upravovány s pomocí rekonstrukční operace nazývané dvouprahový operátor [4],[18]. Pro každý ze čtyř obrazů jsou získány 2 prahy. Obraz segmentovaný užším prahem tvoří *marker* (práh vypočten pomocí Otsu algoritmu), širším prahem je získán obraz *mask* (práh z Otsu algoritmu násoben konstantou z intervalu (0;1)) pro morfologickou rekonstrukci.

V [20] je prezentována metoda morfologického zvýraznění obrazu založeného na základních morfologických operátorech. Spočívá z provedení bottom-hat a top-hat transformací výchozího obrazu a následného přičtení získaného top-hat (zvýraznění pixelů s vysokou intenzitou) obrazu k původnímu za současného odečtení získaného bottom-hat (zvýraznění pixelů s nízkou intenzitou) obrazu.

[19] navrhuje užití zažitých morfologických operátorů ke zvýraznění cévního řečiště a extrakci cév pomocí rozložení bitové palety (8 bitového obrazu), výběru vhodné informace uložené v jednotlivých bitech a následné bitové rekonstrukce. Vychází z předpokladu, že informace uložená v bitech se liší důležitostí a že bity nižšího řádu obsahují především šum, zatímco bity vyššího řádu obsahují pro nás relevantní informace. Po prozkoumání těchto informací jsou pro rekonstrukci vybrány bity s největším podílem informací o cévních strukturách.

V [18] je prezentována myšlenka využití vlastních čísel vypočtených z Hessovy matice založené na obrazových vlastnostech. Vlastní čísla této matice popisují konvexnost a konkávnost struktur obrazu. Vhodným zpracováním lze sestavit obraz, ve kterém jsou zvýrazněny především podélné cévní profily. To lze provést na různých úrovních pro dosažení zvýraznění všech velikostí cév. Vhodnou klasifikací lze opět získat kostru cévního řečiště.

4 METODY MATEMATICKÉ MORFOLOGIE

Jedná se o teorie a techniky analýzy a úpravy obrazů s využitím jejich geometrického tvaru se základy v teoriích množin, topologii a jinde [13].

První ideje se začaly rodit po roce 1960, nejdříve se jednalo o zpracovávání binárních obrazů, později byly existující teorie zobecněny pro šedotónové obrazy, což s sebou přineslo i spoustu dalších nových možností.

Jelikož se MM zabývá velké množství literatury, (nejčastěji citovaným a stěžejním dílem je [13]) a jedná se o velmi komplexní teorie, věnuje se tato práce především jejich aplikaci.

Pro realizaci navržených metod této bakalářské práce je užito programové prostředí MATLAB a existující základní funkce z morfologické části jeho *image processing* toolboxu. Tyto funkce jsou užity pro tvorbu komplexnějších postupů užívaných v praxi.

4.1 Základní morfologické operátory a práce s nimi v prostředí MATLAB

Než se vrhneme do popisu základních funkcí, je potřeba osvětlit pojem strukturní element (SE). V rámci této práce má realizovaný strukturní element podobu dvourozměrné matice sestávající z 0 nebo 1, které mohou být uspořádány do jakéhokoliv tímto způsobem realizovatelného tvaru. Pixely o hodnotě 1 v této matici určují okolí centrálního (právě zpracovávaného) pixelu, které bude při dané operaci bráno v úvahu.

V prostředí MATLAB může být SE vytvořen pomocí funkce *strel*.

Morfologické operace užívající SE jsou zde založeny na systému postupné aplikace SE na pixely vstupního obrazu, srovnání pixelu, který je objektem zájmu, s jeho okolím vymezeným SE a provedením akce v závislosti na zvolené operaci.

Dvě takovéto základní operace (ze kterých vychází mnohé další) jsou dilatace a eroze.

- dilatace: centrální pixel je nastaven na maximální hodnotu z jeho okolí (má za následek odstranění tmavých detailů menších než SE a rozšíření světlých oblastí).
- eroze: centrální pixel nastaven na nejnižší hodnotu jeho okolí (dojde k odstranění světlých detailů menších než SE a k rozšíření tmavých oblastí).

V prostředí MATLAB existují funkce *imdilate* a *imerode* reprezentující tyto operace.

Další operace pro zpracování obrazu mohou být tvořeny po sobě aplikovanými výše popsanými základními operacemi.

Morfologické

- otevření je definováno jako eroze následovaná dilatací (výsledkem je vyhlazení světlých detailů menších než SE),
- uzavření sestává z eroze aplikované po dilataci (výsledkem je vyhlazení tmavých detailů).

V MATLAB jsou realizovatelné pomocí funkcí *imopen* a *imclose*.

Operace morfologické otevření a uzavření lze dále užít pro provedení následujících transformací obrazu:

- top-hat transformace je definována jako rozdíl hodnot původního obrazu a obrazu vzniklého po aplikaci morfologického otevření, dojde k zachování maxim obrazu,
- bottom-hat transformace je definována jako rozdíl hodnot obrazu vzniklého po aplikaci morfologického uzavření a původního obrazu, dojde k zachování minim obrazu.

V MATLAB jsou realizovatelné pomocí funkcí *imtophat* a *imbothat*.

Další užívanou operací MM je morfologická rekonstrukce. Tato metoda užívá dvou obrazů, *markeru* a *masky* k vytvoření finálního rekonstruovaného obrazu (neužívá se zde strukturní element). Obraz *marker* je užít jako „výchozí bod“ rekonstrukce, jejímž smyslem je přiblížení se hodnotám *masky* a obnovení některých částí odstraněných například v předešlých krocích filtrace z obrazu *marker*.

V MATLAB je tato operace realizovaná funkcí *imreconstruct*.

5 NAVRŽENÉ FILTRAČNÍ A SEGMENTAČNÍ TECHNIKY

5.1 Realizace

V programovém prostředí MATLAB jsou realizovány nejčastěji užívané operace pro morfologickou filtraci (dále bylo vyvinuto několik metod nevyužívajících jako svůj základ morfologické operátory) s přihlédnutím k možnostem moderního hardware.

V minulosti byly například pro lineární morfologické otevření užívané strukturní elementy rotující ve 12 orientacích. V roce 2001, do kterého se datuje první metoda zkoumaná v této práci, byly poměrně omezené výpočetní možnosti vzhledem k dnešním.

K morfologické filtraci je přistupováno se dvěma hlavními cíli, prvním je redukce šumu v obraze ve spojení s normalizace pozadí, druhý je samotným zvýrazněním cévních struktur. Výhodou morfologické filtrace je (do jisté míry) realizace obou při užití jediného operátoru.

5.2 Morfologické operace

Tato kapitola pojednává o jednotlivých způsobech filtrace a segmentace, které byly vytvořeny a využity pro potřeby této práce. Jedná se o metody využívající operátory matematické morfologie jako svůj základ.

5.2.1 Otevření lineárním SE definovatelné délky

Aplikace morfologického otevření dle [1] na zelený kanál obrazu (nebo již filtrovaný obraz) přes okolí vymezené lineárním SE délky šířky přibližně nejtlustších cév v obraze má za následek zvýraznění cév ve směrové orientaci tohoto SE a odstranění takových světlých struktur v obraze, do kterých nelze SE vměstnat. Céva probíhající ve stejném směru jako SE zůstane zachována při nastavení okolí vytyčeného SE na jeho nejnížší hodnotu.

Tuto operaci reprezentuje funkce `b_45open`. **Vstupem** funkce je obraz, který chceme filtrovat a délka SE vytyčujícího velikost okolí při filtraci.

Pro naše potřeby je vytvořen soubor 45 SE rotovaných s úhlem 4° . Tyto SE postupně aplikujeme na obraz. Délka SE pro databázi HRF se může pohybovat přibližně v rozmezí 30-40 pixelů. Šířka SE je 1 pixel.

Finální obraz pro další zpracovávání dostaneme výběrem hodnoty intenzity pro každý pixel ze souboru všech směrů, jedná se o hodnotu nejvyšší.

Výstupem funkce je jeden filtrovaný obraz.

Výsledek takovéto operace je zobrazen na *Obrázek 6.2*.

5.2.2 Uzavření lineárním SE definovatelné délky

Aplikace morfologického uzavření (variance na [1]) na zelený kanál obrazu (nebo již filtrovaný obraz) přes okolí vymezené lineárním SE délky šířky přibližně nejtlustších cév v obraze má za následek zvýraznění cév ve směrové orientaci tohoto SE a odstranění takových tmavých struktur v obraze, do kterých nelze SE vměstnat. Céva probíhající ve stejném směru jako SE zůstane zachována při nastavení okolí vytyčeného SE na jeho nejvyšší hodnotu.

Tuto operaci reprezentuje funkce *e_45close*. **Vstupem** funkce je obraz, který chceme filtrovat a délka SE vytyčujícího velikost okolí při filtraci.

Pro naše potřeby je vytvořen soubor 45 SE rotovaných s úhlem 4° . Tyto SE postupně aplikujeme na obraz. Délka SE pro databázi HRF se může pohybovat přibližně v rozmezí 30-40 pixelů. Šířka SE je 1 pixel.

Finální obraz pro další zpracovávání dostaneme výběrem hodnoty intenzity pro každý pixel ze souboru všech směrů, jedná se o hodnotu nejnižší.

Výstupem funkce je jeden filtrovaný obraz.



Obrázek 5.1: Výsledek lineárního uzavření zeleného kanálu pomocí SE délky 37 pixelů ve 45 orientacích

5.2.3 Top-hat transformace lineárním rotujícím SE definovatelné délky


Aplikace morfologické top-hat [1] transformace na obraz přes okolí vymezené lineárním SE délky šířky přibližně nejtlustších cév v obraze provede filtraci obrazu, jejímž výsledkem je zachování nejsvětlejších struktur ve směru odpovídajícímu směrové orientaci užitého SE.

Tuto transformaci reprezentuje funkce *g_tophat*. **Vstupem** funkce je obraz, který chceme transformovat a délka SE vytyčujícího velikost okolí při filtraci.

Pro naše potřeby je vytvořen soubor 45 SE rotovaných s úhlem 4° . Tyto SE postupně aplikujeme na obraz. Délka SE pro databázi HRF se může pohybovat přibližně v rozmezí 30-40 pixelů. Šířka SE je 1 pixel.

Finální obraz pro další zpracovávání dostaneme výběrem hodnoty intenzity pro každý pixel ze souboru všech směrů, jedná se o hodnotu nejvyšší.

Výstupem funkce je jeden transformovaný obraz.



Obrázek 5.2: Výsledek top-hat transformace (obrazu po aplikaci lineárního otevření a rekonstrukci) s lineárním SE délky 37 pixelů ve 45 orientacích (při aplikaci na negativ původního obrazu totožné s bottom-hat; obrázek upraven v Adobe PS pro lepší vypovídací hodnotu)

5.2.4 Bottom-hat transformace rotujícím SE definovatelné délky


Aplikace morfologické bottom-hat (variace na [1]) transformace na obraz přes okolí vymezené lineárním SE délky šířky přibližně nejtlustších cév v obraze provede filtraci obrazu, jejímž výsledkem je zachování nejtmažších struktur ve směru odpovídajícímu směrové orientaci užitého SE.

Tuto transformaci reprezentuje funkce f_bothat . **Vstupem** funkce je obraz, který chceme transformovat a délka SE vytyčujícího velikost okolí při filtraci.

Pro naše potřeby je vytvořen soubor 45 SE rotovaných s úhlem 4° . Tyto SE postupně aplikujeme na obraz. Délka SE pro databázi HRF se může pohybovat přibližně v rozmezí 30-40 pixelů. Šířka SE je 1 pixel.

Finální obraz pro další zpracovávání dostaneme výběrem hodnoty intenzity pro každý pixel ze souboru všech směrů, jedná se o hodnotu nejvyšší.

Výstupem funkce je jeden transformovaný obraz.



Obrázek 5.3: Výsledek bottom-hat transformace (obrazu po aplikaci lineárního otevření a rekonstrukci) s lineárním SE délky 37 pixelů ve 45 orientacích (obrázek upraven v Adobe PS pro lepší vypovídací hodnotu)

5.2.5 Morfologické zvýraznění obrazu

Vhodným výběrem morfologických operátorů je možné dosáhnout zvýraznění kontrastu v obraze [20]. Realizace spočívá v aplikaci morfologické bottom- a top-hat transformace na obraz, který má být zpracován. Nejdříve je výsledek top-hat transformace k původnímu obrazu přičten, dále pak výsledek bottom-hat transformace je od takto získaného obrazu odečten.

Tuto operaci reprezentuje funkce *MorfologickyEnhance*. **Vstupem** funkce je obraz, který chceme transformovat a délka SE vytyčujícího velikost okolí při bottom-hat a top-hat transformaci.

Parametry strukturních elementů pro bottom- a top-hat transformace mohou být zachovány s nastavením uvedeným výše.

Výstupem funkce je jeden transformovaný obraz.

Výsledek takovéto operace je zobrazen na *Obrázek 6.4*

5.2.6 Modifikovaná víceúrovňová top-hat transformace

Aplikace modifikované víceúrovňové top-hat transformace dle [4] na obraz umožňuje úpravu obrazu na několika úrovních vymezených velikostmi SE, jejímž výsledkem je zachování nejsvětlejších struktur obrazu s různou přesností.

Tuto operaci reprezentuje funkce *Multiscale_rec_tophat*. **Vstupem** funkce je obraz, který chceme transformovat.

Pro naše potřeby je vytvořen soubor 8 SE s narůstající velikostí pro morfologické otevření a 1 SE konstantní velikosti pro morfologické uzavření. SE pro uzavření je diskový s velikostí odpovídající přibližně nejtenčím cévám v obrazu. SE pro otevření pokrývají celou škálu velikostí cév ve velikostech 5, 9, 13, 17, 21, 25, 29 a 33 pixelů.

Modifikace top-hat transformace spočívá v uzavření obrazu před jeho otevřením. Obraz jedenkrát uzavřený je tedy následně osmkrát otevřen s různou velikostí SE. Subtrakcí otevřených obrazů do původního obrazu získáme 8 různých top-hat obrazů, které jsou postupně ve dvojicích (1. s 2., 3. s 4., ...) průměrovány pro redukci šumu. Výsledkem jsou 4 obrazy, každý filtrován s různou úrovní přesnosti.

Tato funkce v současné iteraci obsahuje také integrovaný dvouprahový operátor (popis v následující podkapitole). **Výstupem** funkce jsou 3 rekonstruované binární obrazy (přínos nejvyšší úrovně rekonstrukce je diskutabilní a pro finální obraz není využita).

Výsledky takovéto operace jsou vyobrazeny na *Obrázek 6.5*, *Obrázek 6.6* a *Obrázek 6.7*.

5.2.7 Dvouprahová morfologická binární rekonstrukce (dvouprahový operátor)

Obecně morfologická rekonstrukce užívá obrazů *marker* a *mask*, *marker* jako zdroj výchozích bodů pro rekonstrukci a *mask* jako její potenciální hranici [4], [19], [20].

Tuto operaci reprezentuje funkce *DTO*. **Vstupem** funkce je obraz, který chceme segmentovat (odpovídající charakteristikám bottom-hat na *Obrázek 5.3*).

Z obrazu, který chceme segmentovat, je získán užší práh (pro obraz *marker*) a širší práh (pro obraz *mask*). Užší práh může být získán pomocí Otsu algoritmu, širší práh pak násobením užšího číslem z intervalu (0;1). Následně je provedena binární morfologická rekonstrukce takto prahovaných obrazů.

Výstupem funkce je jeden prahovaný obraz.

Výsledky takovéto operace jsou vyobrazeny na *Obrázek 6.8*, *Obrázek 6.9* a *Obrázek 6.10*.

5.3 Nemorfologické operace

Tato kapitola pojednává o jednotlivých způsobech filtrace a segmentace, které byly vytvořeny a využity pro potřeby této práce. Jedná se o metody využívající jiné postupy než operátory matematické morfologie jako svůj základ.

5.3.1 DooG filtrace

Tuto operaci reprezentuje funkce *DooG*. **Vstupem** funkce je obraz, který chceme filtrovat.


Konvolucí obrazu s filtry Difference of offset Gaussians [4], [19] podoby uvedené na *Obrázek 5.4* rotovanými v úhlech 0°, 30°, 60°, 90°, 120°, 150° vytvoříme 6 obrazů. Nejvyšší odezva obrazu je v místech přelomu kladné derivace do záporné. Pro potlačení šumu a zvýraznění je na každou směrovou orientaci možno aplikovat morfologické filtrační metody. Vhodnou klasifikací lze získat informaci o průběhu cévního řečiště.

$$\begin{bmatrix} -1 & -2 & 0 & 2 & 1 \\ -2 & -4 & 0 & 4 & 2 \\ -1 & -2 & 0 & 2 & 1 \end{bmatrix}$$

Obrázek 5.4: Jedna z šesti směrových orientací DooG filtru, převzato z [4]



Obrázek 5.5: Výsledek jedné směrové orientace DooG filtrace po aplikaci MM otevření



Obrázek 5.6: Výsledek složení všech směrových orientací DooG filtrace (segmentace pomocí *Dvouprahová morfologická binární rekonstrukce (dvouprahový operátor)*)

5.3.2 Obraz na základě vlastních čísel Hessiany matice

Tuto operaci reprezentuje funkce *vl_cisla*. **Vstupem** funkce je obraz, který chceme filtrovat a hodnota σ Gaussovske funkce [21] udávající úroveň, na které bude operace provedena.

Hessova matice je v tomto případě čtvercovou maticí vytvořenou pro každý pixel dle *Obrázek 5.7*.

$$H = \begin{bmatrix} I_{xx}(x_0) & I_{xy}(x_0) \\ I_{yx}(x_0) & I_{yy}(x_0) \end{bmatrix}$$

Obrázek 5.7: Hessova matice pro každý obrazový bod reprezentující jeho vlastnosti v tomto bodě; převzato z [18]

Druhé parciální derivace odpovídají hodnotám pixelu z obrazů získaných konvolucí původního obrazu s filtry druhých parciálních derivací Gaussovske funkce. Pro každý pixel jsou z této matice vypočítána 2 vlastní čísla, která dávají informaci o zakřivení profilu obrazu v tomto bodě. Při vhodném výběru vypočtených vlastních čísel pro každý pixel lze složit obraz, jehož maxima odpovídají v největší míře profilům cév.

Parametr σ Gaussovy funkce udává úroveň, na které bude tato operace provedena. **Výstupem** jsou 2 obrazy charakterizující zakřivení profilu obrazu.

Pro další zpracování jsou vybrána taková vlastní čísla, jejichž obraz má charakter, jaký vidíme na *Obrázek 6.11* a *Obrázek 6.12*.

5.3.3 Dělení bitové palety a bitová rekonstrukce


Obrazová informace je uložena v jednotlivých bitech s narůstající důležitostí od bitů nižší úrovně po bity vyšší úrovně [19]. Tuto informaci lze rozdělit, rozřídít a poté rekonstruovat na výsledný obraz částečně rekonstruovaného cévního řečiště.

Tato operace je realizována skriptem *Bit_final*, který obsahuje 3 funkce.


- *bit_prepare* převede obrazovou matici (**vstup**) do požadovaného formátu uint8 (**výstup**)
- *bit_slice* rozloží informace z uint8 obrazu (**vstup** spolu s maskou) uložené v jednotlivých bitech do samostatných obrazů a zobrazí je (**výstup** tvoří 8 obrazů)

Separací a zobrazením informace uložené v jednotlivých bitech jsme pro každý pixel schopni vybrat bity úrovní, které mají pro nás relevantní obrazovou informaci a provést bitovou rekonstrukci pro zachování pouze vybrané informace v jednom obraze.


- *bitrecon*- **vstupem** je matice 8 obrazů z *bit_slice* (a maska), úpravou funkce lze vybrat úrovně bitů, ze kterých chceme rekonstruovat informaci. **Výstup** tvoří 1 rekonstruovaný obraz.



Obrázek 5.8: Informace uložená v bitech 1-4



Obrázek 5.9: Informace uložená v bitech 5-8



Obrázek 5.10: Výsledek bitové rekonstrukce (informace z bitů 5 a 6)

5.4 Pomocné funkce

5.4.1 Hodnocení snímků

Pro hodnocení účinnosti algoritmu byl vytvořen jednoduchý skript *eval_filt1*. Tento skript vypočte ve snímku hodnoty true positive (TP), true negative (TN), false positive (FP) a false negative (FN) v prostoru vymezeném pomocí masky.

Z těchto hodnot vypočte senzitivitu, specificitu a přesnost dle [18].

5.4.2 Přepočet obrazových hodnot

Funkce *rescale_gray* provede přepočet hodnot obrazů složených z vlastních čísel Hessianovy matice tak, aby byly využitelné v dalších krocích.


Nejdříve vypočítá maxima a minima vstupního obrazu a následně dělí rozdíl obrazových hodnot a minima obrazu rozdílem maxima a minima obrazu.

6 NAVRŽENÁ METODA

Výchozí obrazy obsahují poměrně velké množství struktur a šumu bránící jednoduché segmentaci cévního řečiště, MM však zahrnuje užitečné metody pro filtraci takového obrazu. Celý postup filtrace se dá rozdělit na několik částí dle užitých operátorů.

Přestože bylo navrženo několikero filtračních a segmentačních technik, z praktických důvodů (náročnost na hardware či velmi podobná účinnost) jsou pro zapojení do finálního algoritmu vybrány jen některé (jejich určitá sekvence). Ty byly vybrány na základě výsledků hodnocení statistického a subjektivního.

Algoritmus se po předzpracování skládá ze dvou větví, jejichž výsledky jsou nakonec kombinovány. Je realizován jako skript *final*.



Obrázek 6.1: Blokové schéma navržené metody

6.1 Předzpracování obrazu

Funkce *a_nacitani*, jejíž **vstupy** jsou postupně zvolený obraz, jeho maska a zlatý standard zpracuje a pošle na výstup tato data v podobě požadované pro další zpracování. Výstupem jsou tedy obraz, maska a zlatý standard uložené v libovolných proměnných.

6.1.1 Aplikace morfologického otevření

Užitím této metody se lze zbavit šumu a detailů s vysokou intenzitou menších než strukturní element, které jsou v obrazu obsaženy, za současného zvýraznění cév.

V tomto případě je užit lineární strukturní element délky 37 pixelů pro každou ze 45 směrových orientací.

Takovýto obraz však ztrácí některé detaily především ve formě porušení spojitosti tenkých cév, což se snažíme napravit dalším krokem.



Obrázek 6.2: Výsledek lineárního otevření obrazu zeleného kanálu pomocí SE délky 37 pixelů ve 45 orientacích

6.1.2 Morfologická rekonstrukce


Tímto krokem je provedení morfologické rekonstrukce otevřeného obrazu. Výsledkem je ideálně obraz se zvýrazněným řečištěm s lepším rozlišením tenkých cév, než tomu bylo u samotného otevření.



Obrázek 6.3: Výsledek morfologické rekonstrukce otevřeného obrazu dle původního obrazu zeleného kanálu

6.1.3 Morfologické zvýraznění obrazu

Má za následek zvýšení kontrastu rekonstruovaného obrazu.




Obrázek 6.4: Výsledek morfologického zvýraznění obrazu

6.2 Morfologická top-hat transformace a rekonstrukce


6.2.1 Víceúrovňová modifikovaná top-hat transformace a dvouprahový operátor

Touto transformací získáme filtrované obrazy cévního řečiště na 4 úrovních, každý z nich by měl obsahovat primárně informace o jiné části řečiště.


.



Obrázek 6.5: Výsledek modifikované top-hat transformace (rekonstruovaného obrazu) s cirkulárním SE (průměr obrazů s užitím SE o průměrech 5 a 9 pixelů)



Obrázek 6.6: Výsledek modifikované top-hat transformace (rekonstruovaného obrazu) s cirkulárním SE (průměr obrazů s užitím SE o průměrech 13 a 17 pixelů)




Obrázek 6.7: Výsledek modifikované top-hat transformace (rekonstruovaného obrazu) s cirkulárním SE (průměr obrazů s užitím SE o průměrech 21a 25 pixelů)

Pomocí *Otsu* algoritmu je vypočítán práh pro *marker*, práh pro *mask* je v tomto případě 85% *marker* prahu. Morfologickou rekonstrukcí binárních obrazů je získána sada 4 (3) částečně segmentovaných obrazů cévního řečiště.


Funkce *clear_tophat_img* zde realizuje úlohu *postprocessing*. Její **vstup** tvoří sada 4 částečně segmentovaných obrazů cévního řečiště a maska.

Úkolem této funkce je odstranit z obrazů jednotlivých úrovní spojitě objekty menší než je definovaná velikost a následně spojit tyto obrazy dohromady.


Výstupem je jeden binární obraz částečně rekonstruovaného cévního řečiště.



Obrázek 6.8: Výsledek dvouprahového operátoru pro první obraz získaný pomocí Víceúrovňová modifikovaná top-hat transformace



Obrázek 6.9: Výsledek dvouprahového operátoru pro druhý obraz získaný pomocí Víceúrovňová modifikovaná top-hat transformace



Obrázek 6.10: Výsledek dvouprahového operátoru pro třetí obraz získaný pomocí *Víceúrovňová modifikovaná top-hat transformace*


6.3 Získání profilů cév pomocí vlastních čísel Hessoovy matice

6.3.1 Tvorba obrazu profilů cév z vlastních čísel Hessoovy matice


Funkce *curvature* se **vstup** zpracovává obraz, σ_1 , σ_2 , l (délka strukturního elementu) volá funkci *vl_cisla* pro 2 úrovně σ_7 a $\sqrt{8}$. První úroveň obsahuje především zvýrazněné profily širších, druhá úroveň tenkých cév. Dále vybírá obraz odpovídající nejmenšímu zakřivení profilu pro každou z těchto úrovní. Tyto 2 obrazy jsou následně zpracovány funkcí *rescale_gray* pro přepočet rozpětí hodnot (výsledek je vhodnější k dalšímu zpracování).

Výstup tvoří obrazy zvýrazněného cévního řečiště na 2 úrovních.


Ty jsou dále zpracovány funkcí *BW_curv*, kde Otsu metodou jsou oba výsledné obrazy (**vstup** spolu s maskou) prahovány, na nich jsou provedeny *postprocessing* úpravy (vymazání spojitých struktur definované velikosti). Poté jsou oba obrazy složeny, tento obraz tvoří **výstup**.




Obrázek 6.11: Obráz získaný z vlastních čísel Hessianovy matice na úrovni $\sigma=7$



Obrázek 6.12: Obráz získaný z vlastních čísel Hessianovy matice na úrovni $\sigma=\sqrt{8}$




Obrázek 6.13: Výsledný obraz získaný z vlastních čísel Hessianovy matice na úrovni $\sigma=7$ po prahování a *postprocessing* úpravách



Obrázek 6.14: Výsledný obraz získaný z vlastních čísel Hessianovy matice na úrovni $\sigma=\sqrt{8}$ po prahování a *postprocessing* úpravách

6.4 Získání výsledků

Obě větve algoritmu produkují částečnou rekonstrukci cévního stromu. Jejich složením vzniká finální obraz.



Obrázek 6.15: Výsledný obraz segmentovaného cévního řečiště

7 ZHODNOCENÍ DOSAŽENÝCH VÝSLEDKŮ

7.1 Hodnocení navrženého algoritmu

7.1.1 Dosažené výsledky

Navrženým algoritmem byla zpracována celá databáze HRF. Ze získaných snímků byla vzhledem ke zlatým standardům spočítána senzitivita, specifická a přesnost v oblasti vymezené maskou. Z těchto hodnot byl vypočten aritmetický průměr a směrodatná odchylka. Jednotlivé části databáze, tedy snímky s glaukomem, diabetickou retinopatií a zdravého oka byly vyhodnoceny samostatně. Dosažené výsledky jsou prezentovány v *Tabulka 7.1*, *Tabulka 7.2* a *Tabulka 7.3*. Nejvyšší a nejnižší dosažené hodnoty jsou zvýrazněny.

Tabulka 7.1: Vyhodnocení účinnosti algoritmu na skupině obrázků DR z HRF databáze

Diabetická retinopatie	Specifická	Senzitivita	Přesnost
1	0,9538	0,8300	0,9463
2	0,9526	0,8119	0,9419
3	0,9528	0,7863	0,9408
4	0,9544	0,7614	0,9414
5	0,9587	0,8387	0,9498
6	0,9460	0,7127	0,9251
7	0,9553	0,8118	0,9420
8	0,9539	0,8041	0,9405
9	0,8353	0,8323	0,8351
10	0,9637	0,7521	0,9417
11	0,9637	0,7872	0,9460
12	0,9543	0,7769	0,9399
13	0,9661	0,7590	0,9493
14	0,9419	0,8269	0,9296
15	0,9339	0,8145	0,9246
Aritmetický průměr	0,9458	0,7937	0,9329
Směrodatná odchylka	0,0306	0,0347	0,0272

Tabulka 7.2: Vyhodnocení účinnosti algoritmu na skupině obrázků G z HRF databáze

Glaukom	Specifická	Senzitivita	Přesnost
1	0,9603	0,8123	0,9485
2	0,9594	0,8113	0,9463
3	0,8459	0,8693	0,8475
4	0,8929	0,8888	0,8926
5	0,9734	0,7632	0,9571
6	0,9692	0,7765	0,9535
7	0,9736	0,7915	0,9595
8	0,9627	0,8361	0,9525
9	0,9632	0,8028	0,9505
10	0,9665	0,8132	0,9546
11	0,9669	0,7986	0,9517
12	0,9631	0,8037	0,9475
13	0,9664	0,7647	0,9501
14	0,9554	0,7739	0,9402
15	0,9635	0,7801	0,9475
Aritmetický průměr	0,9522	0,8057	0,9400
Směrodatná odchylka	0,0339	0,0349	0,0290


Tabulka 7.3: Vyhodnocení účinnosti algoritmu na skupině obrázků H z HRF databáze

Zdravé oko	Specifická	Senzitivita	Přesnost
1	0,9828	0,7217	0,9512
2	0,9803	0,8188	0,9613
3	0,9796	0,6961	0,9439
4	0,9768	0,7752	0,9542
5	0,9828	0,7682	0,9597
6	0,9776	0,8173	0,9583
7	0,9748	0,8126	0,9576
8	0,9805	0,8075	0,9598
9	0,9833	0,7421	0,9610
10	0,9802	0,7593	0,9576
11	0,9736	0,8533	0,9603
12	0,9796	0,8513	0,9636
13	0,9667	0,8297	0,9525
14	0,9663	0,7951	0,9485
15	0,9702	0,8374	0,9578
Aritmetický průměr	0,9770	0,7924	0,9565
Směrodatná odchylka	0,0054	0,0457	0,0052

7.1.2 Diskuze výsledků

Z aritmetických průměrů výsledků lze soudit, že klasifikace všech částí databáze byla na srovnatelné úrovni. Dosažená přesnost klasifikace poukazuje k očekávanému faktu, tedy nejvyšší četnosti správného přiřazení pixelů cévnímu řečišti u obrazů zdravého oka. Přesnost se pak snižuje u oka s glaukomem a ještě více u oka s diabetickou retinopatií.

Na *Obrázek 6.15* je případ s nejvyšší dosaženou přesností vůbec. Na následujícím obrázku *Obrázek 7.1* je naopak výsledek s nejnižší dosaženou přesností.



Obrázek 7.1: Obraz s nejhorší celkovou úrovní klasifikace

Celkové nejnižší hodnoty senzitivity vyplývají z neschopnosti přesně určit nejtenčí kapiláry v obraze, což představuje jeden z největších problémů morfologické filtrace spolu s problémem identifikace velkých ložisek diabetické retinopatie.

Pro porovnání jsou v následujících tabulkách uvedeny dosažené výsledky některých zde citovaných prací.

Tabulka 7.4: Průměrné hodnoty dosažených výsledku předešlých prací zabývajících se tímto tématem (výsledky pro databázi DRIVE)

DRIVE	Specificita	Senzitivita	Přesnost
Zana [1]	-	0,6971	0,9377
Mendonca [4]	0,9764	0,7344	0,9452
Fraz [18]	0,9798	0,6879	0,9419

Tabulka 7.5: Průměrné hodnoty dosažených výsledku předešlých prací zabývajících se tímto tématem (výsledky pro databázi STARE)

STARE	Specificita	Senzitivita	Přesnost
Mendonca [4]	0,9730	0,6996	0,9440
Fraz [18]	0,9670	0,7425	0,9434

Pokud pomineme fakt velkého rozdílu rozlišení výchozích snímků (odráží se především v hodnotách senzitivity) užitých v těchto pracích, dá se konstatovat, že navržená metoda je i přes její nedostatky na srovnatelné úrovni.

V [1], [4] a [18] je obecně dosahováno nižších hodnot senzitivity pravděpodobně převážně v důsledku nízkého rozlišení snímků. Metody mají v některých případech vyšší specificitu a přesnost než metoda zde prezentovaná.

Hodnocení je však zavádějící, pokud není provedeno na stejné databázi. V [22] je hodnocena metoda založená na přizpůsobené filtraci aplikovaná právě na HRF databázi. Dosažené výsledky jsou v *Tabulka 7.6*, *Tabulka 7.7* a *Tabulka 7.8*.

Tabulka 7.6: Vyhodnocení algoritmu na skupině obrázků DR z HRF databáze dle [22]

Diabetická retinopatie	Specificita	Senzitivita	Přesnost
Aritmetický průměr	0,9619	0,7463	0,9445
Směrodatná odchylka	0,0077	0,0566	0,0084

Tabulka 7.7: Vyhodnocení algoritmu na skupině obrázků G z HRF databáze dle [22]

Glaukom	Specificita	Senzitivita	Přesnost
Aritmetický průměr	0,9638	0,7900	0,9497
Směrodatná odchylka	0,0069	0,0318	0,0061

Tabulka 7.8: Vyhodnocení algoritmu na skupině obrázků H z HRF databáze dle [22]

Zdravé oko	Specifická	Senzitivita	Přesnost
Aritmetický průměr	0,9750	0,7861	0,9539
Směrodatná odchylka	0,0065	0,0392	0,0061

Dosažené průměrné hodnoty specifickosti a přesnosti jsou pro databázi DR a G HRF lepší v případě [22]. Zde navržená metoda disponuje vyšší senzitivitou, což je při nízké celkové přesnosti irelevantní. Lepší výsledky naopak vykazuje na databázi H HRF.

Ve většině případů má zde navržená metoda vyšší odchylku poukazující na nestabilitu segmentace za náročnějších podmínek (více šumu, artefakty databáze DR,G).

7.1.3 Hodnocení algoritmu

Algoritmus je silně závislý na nastavení takových parametrů, jako jsou velikost SE, úroveň σ , na kterých dochází k získání informace pro výpočet obrazu z vlastních čísel Hessianovy matice, nebo například přidání dalších filtračních procesů. Experimentálně byla ověřena možnost zvýšení průměrné specifickosti a přesnosti výsledků v některých případech o více než 1% při zachování srovnatelné hodnoty senzitivity. Toho bylo docíleno aplikací MM otevření na filtrované obrazy bezprostředně před aplikací dvouprahového operátoru a prahování v obou větvích algoritmu. Při tomto nastavení byla segmentována databáze HRF jednou ze starších iterací metody při dosažení následujících výsledků:

Tabulka 7.9: Vyhodnocení účinnosti starší iterace algoritmu na skupině obrázků DR z HRF databáze

Diabetická retinopatie	Specifická	Senzitivita	Přesnost
Aritmetický průměr	0,9595	0,7864	0,9451
Směrodatná odchylka	0,0084	0,0401	0,0076

Tabulka 7.10: Vyhodnocení účinnosti starší iterace algoritmu na skupině obrázků G z HRF databáze

Glaukom	Specifická	Senzitivita	Přesnost
Aritmetický průměr	0,9642	0,8048	0,9510
Směrodatná odchylka	0,0147	0,0310	0,0119

Tabulka 7.11: Vyhodnocení účinnosti starší iterace algoritmu na skupině obrázků H z HRF databáze

Zdravé oko	Specifická	Senzitivita	Přesnost
Aritmetický průměr	0,9834	0,7856	0,9613
Směrodatná odchylka	0,0043	0,0502	0,0051

Vyšší dosažená přesnost ovšem přichází za cenu více než trojnásobného zvýšení výpočetního času. Na notebooku s Intel Core 2 Duo P8400 2.6Ghz a 4,00 GB RAM je doba zpracování obrazu metodou v současné verzi přibližně 7 minut. Přidáním MM otevření na obraz nejnižší úrovně modifikované top-hat transformace a oba obrazy složené z vlastních čísel Hessovy matice má za následek doby zpracování převyšující 20 minut.

Jednotlivé filtrační algoritmy fungují dle očekávání a mohou být zapojeny do segmentačních procesů. V této práci jsou však použity pouze základní klasifikační metody, což pravděpodobně srazí kvalitu dosažených výsledků navržené metody. Tyto metody stojí na principu globálního prahování, které vzhledem k povaze některých obrázků není ideální.

V případě dvouprahového operátoru by mohlo být vhodné vypočtení prahu pro obraz *mask* na základě některých obrazových parametrů namísto užití pevné hodnoty 85%.

Mnohem užitečnější by také mohlo být využití pokročilejších pokud možno dynamických klasifikátorů, které by braly v potaz variace hodnot v různých částech obrázků.

7.2 Postupy nevyužité v navržené metodě

7.2.1 DooG filtrace

Z výsledku, který vidíme na *Obrázek 5.5* lze usuzovat na užitečné zvýraznění cévních struktur a po úroveň nejtenčích cév, při pokusu o dvouprahovou morfologickou rekonstrukci a složení všech směrových orientací obrázků na *Obrázek 5.6* však vidíme, že by bylo nutno vyvinout speciální klasifikátor pro správné zpracování informace z takového obrázu.

Tabulka 7.12: Výsledek vyhodnocení *Obrázek 5.6* pomocí dvouprahového operátoru (obraz 12_h)

	Specifická	Senzitivita	Přesnost
DooG	0,9624	0,3159	0,8818
Bottom-hat	0,9891	0,7543	0,9598

Z pokusu o vyhodnocení metody v současném stavu vyplývá o poznání horší účinnost i oproti jednoduché bottom-hat transformaci při užití stejné klasifikační techniky.

7.2.2 Dělení bitové palety a bitová rekonstrukce

Tabulka 7.13: Výsledek vyhodnocení *Obrázek 5.10* (obraz 12_h)

	Specifická	Senzitivita	Přesnost
Bit rekonstrukce	0,9983	0,5215	0,9389
Dvouprahový operátor	0,9891	0,7543	0,9598

Alternativní jednoduchá a rychlá segmentační metoda k dvouprahové rekonstrukci, která však disponuje poměrně špatným rozeznáváním kapilár (o poznání nižší senzitivita, viz *Tabulka 7.13*) při využití informace z bitů 5 a 6 a naopak vyšším počtem artefaktů ve finálním obraze při užití informace z bitů 4,5 a 6 než ve dvouprahové rekonstrukci (využita v navržené segmentační metodě).

8 ZÁVĚR

Téma práce je segmentace cévního řečiště na snímcích sítnice s využitím matematické morfologie. V dnešní době je velká snaha o automatizaci analytických a diagnostických metod ve všech vědních odvětvích. Práce jako tato jsou nedílnou součástí automatizačního procesu. Metody matematické morfologie se v kontextu filtrace a segmentace cévního řečiště užívají s různým stupněm úspěchu již více než 10 let a jsou předmětem mnoha publikovaných prací.

Dle zadání bylo vyvinuto několik filtračních a segmentačních algoritmů, s účelem zvýraznění, popřípadě extrakce cévního řečiště ze snímků sítnice, na jejichž základě byla navržena metoda automatické segmentace.

Navržená metoda je implementována v programovém prostředí MATLAB. Skládá se z několika dílčích funkcí, které mohou být samostatně užity pro filtraci při zapracování do jiných metod. Také z nich může být sestavena samostatná metoda jiná, než zde prezentovaná.

K metodě není nutno přistupovat jako k finálnímu řešení, spíše naopak. Kvůli různorodosti obrazů v databázi jsou některé parametry (velikost odstraňovaných nespojitých objektů...) nastaveny takovým způsobem, že dochází například ke snížení přesnosti u obrazů bez artefaktů, ale s nižším kontrastem. Při individuálním nastavení pro každý obraz lze dosáhnout lepších výsledků než při univerzálním nastavení, kterým byla testována celá databáze.

To však nesplňuje podmínku autonomní funkce. Jako výhled do budoucna by ideálním řešením mohlo být zapojení pokročilejších dynamických klasifikátorů pro zlepšení přesnosti klasifikace pixelů cévního řečiště.

Jisté zlepšení současné podoby metody je aplikace více morfologických operátorů během jeho chodu, to má ovšem velmi nepříznivý vliv na výpočetní dobu.

Další možností je zařadit výsledky jednotlivých filtračních metod prezentovaných v této práci do většího souboru příznaků, ze kterého by pak probíhala klasifikace.

V porovnání s další metodou aplikovanou na databázi HRF zde prezentovaný algoritmus dosahuje nižší přesnosti klasifikace cévních struktur, dalším experimentováním a modifikacemi je však možno ji zlepšit na odpovídající úroveň.

LITERATURA

- [1] ZANA, F. a KLEIN, J.-C.. Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation. *IEEE Transactions on Image Processing*. vol. 10, issue 7, s. 1010-1019. DOI: 10.1109/83.931095. Dostupné z:
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=931095>
- [2] FANG, B., HSU, W. a LEE, M.L. Reconstruction of vascular structures in retinal images. *Proceedings 2003 International Conference on Image Processing (Cat. No.03CH37429)*. IEEE, 2003, II-157-60. DOI: 10.1109/ICIP.2003.1246640. Dostupné z:
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1246640>
- [3] HAJER, J., KAMEL, H. a NOUREDDINE, E. Blood Vessels Segmentation in Retina image using Mathematical Morphology and the STFT analysis. *2006 2nd International Conference on Information*. IEEE, 2006, s. 1130-1134. DOI: 10.1109/ICTTA.2006.1684533. Dostupné z:
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1684533>
- [4] MENDONCA, A.M. a CAMPILHO, A. Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction. *IEEE Transactions on Medical Imaging*. 2006, vol. 25, issue 9, s. 1200-1213. DOI: 10.1109/TMI.2006.879955. Dostupné z:
<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?tp=&arnumber=1677726&queryText%3Dmendonca+2006+centerlines>
- [5] ODSTRČILÍK, J., et al. Improvement of Vessel Segmentation by Matched Filtering in Colour Retinal Images. *IFMBE Proceedings*, vol. 25, pp. 327-330, 2009.
- [6] GIANINI A., GRISAN E., RUGGERI A.: Enhanced Classification-Based Vessel Tracking Using Vessel Models and Hough Transform. *Proc. of the 3rd European Medical and Biological Engineering Conference EMBEC 2005*. November 20-25, 2005, Prague, Czech Republic. vol. 11, no.1, ISSN 1727-1983

- [7] FRANGI, F., NIESSEN, W. J., VINCKEN, K. L., VIERGEVER, M. A., a WELLS, W. M. Medical image computing and computer-assisted intervention--MICCAI '98: first international conference, Cambridge, MA, USA, October 11-13, 1998 : proceedings. New York: Springer, c1998, xxii, 1256 p. ISBN 35-406-5136-5.
- [8] YAO, Ch., CHEN, H. Automated retinal blood vessels segmentation based on simplified PCNN and fast 2D-Otsu algorithm. *Journal of Central South University of Technology*. 2009, vol. 16, issue 4, s. 640-646. DOI: 10.1007/s11771-009-0106-3. Dostupné z: <http://link.springer.com/10.1007/s11771-009-0106-3>
- [9] SVOBODA, O.: Hodnocení automatických metod segmentace cévního řečiště. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 56 s., 1 příloha. Vedoucí bakalářské práce Ing. Jan Odstrčilík.
- [10] DRIVE: Digital Retinal Images for Vessel Extraction [online]. [cit. 2013-05-25]. Dostupné z: <http://www.isi.uu.nl/Research/Databases/DRIVE/>
- [11] STructured Analysis of the Retina [online]. [cit. 2013-05-25]. Dostupné z: <http://www.parl.clemson.edu/~ahoover/stare/index.html>
- [12] High-Resolution Fundus (HRF) Image Database [online]. [cit. 2012-12-11]. Dostupné z: <http://ophthalgo.ubmi.feec.vutbr.cz/ophthalgo/page/hrf-database>
- [13] SERRA, J. P. *Image analysis and mathematical morphology*. New York: Academic Press, 1982-1988, v. <1-2 >. ISBN 01-263-7240-3.
- [14] CANON KABUSHIKI KAISHA (Tokyo, JP). *Fundus camera* [patent]. ITOH H., TANAKA S., TAKAI M. Zapsáno 15.4.2009. A61B 3/12, A61B 3/14. 12/424431. United States Patent Application.
- [15] KOLÁŘ, R. Lékařská diagnostická technika. 2007. ISBN: ABM 07-91.
- [16] HLOŽÁNEK, M. a BRŮNOVÁ B. *Přístrojová technika v oftalmologii*. 1. vyd. Praha: Univerzita Karlova, 2. lékařská fakulta, 2006, 28 s. ISBN 80-902-1609-9.

- [17] HOLIBKOVÁ, A. a LAICHMAN, S. *Přehled anatomie člověka*. 4. vyd. Olomouc: Univerzita Palackého v Olomouci, 2006, 140 s. ISBN 80-244-1480-5.
- [18] FRAZ, M. M., BASIT, A., REMAGNINO, P., HOPPE, A. a BARMAN, S. A. Retinal vasculature segmentation by morphological curvature, reconstruction and adapted hysteresis thresholding. 2011 7th International Conference on Emerging Technologies. IEEE, 2011, s. 1-6. DOI: 10.1109/ICET.2011.6048487. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6048487>
- [19] FRAZ, M. M., JAVED, M. Y. a BASIT, A. Evaluation of retinal vessel segmentation methodologies based on combination of vessel centerlines and morphological processing. *2008 4th International Conference on Emerging Technologies*. IEEE, 2008, s. 232-236. DOI: 10.1109/ICET.2008.4777506. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4777506>
- [20] XU, J., ISHIKAWA, H., WOLLSTEIN, G. a SCHUMAN, J. S. Retinal vessel segmentation on SLO image. *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2008, s. 2258-2261. DOI: 10.1109/IEMBS.2008.4649646. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4649646>
- [21] MARTINEZ-PEREZ, M. E., HUGHES, A. D., THOM, S. A., BHARATH, A. A., PARKER, K. H. Segmentation of blood vessels from red-free and fluorescein retinal images. *Medical Image Analysis*, Volume 11, Issue 1, February 2007, Pages 47-61, ISSN 1361-8415, Dostupné z: <http://www.sciencedirect.com/science/article/pii/S1361841506000909>
- [22] ODSTRČILIK, J., KOLAR, R., BUDAI, A., HORNEGGER, J., JAN, J., GAZAREK, J., KUBENA, T., CERNOSEK, P., SVOBODA O. a ANGELOPOULOU, E. Retinal vessel segmentation by improved matched filtering: evaluation on a new high-resolution fundus image database. *IET Image Process*. 2013, pp. 1–11. DOI: 10.1049/iet-ipr.2012.0455.

- [23] GOLDBAUM, M., MOEZZI, S., TAYLOR, A., CHATTERJEE, S., BOYD, HUNTER, J. E. a JAIN, R. Automated diagnosis and image understanding with object extraction, object classification, and inferencing in retinal images. *Proceedings of 3rd IEEE International Conference on Image Processing* [online]. IEEE, 1996, s. 695-698 [cit. 2013-05-23]. DOI: 10.1109/ICIP.1996.560760. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=560760>