



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**

KLASIFIKACE CÉVNÍHO ŘEČIŠTĚ NA SNÍMCÍCH SÍTNICE

CLASSIFICATION OF THE VASCULAR TREE IN FUNDUS IMAGES

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

BC. IULIIA TEBENKOVA

VEDOUcí PRÁCE
SUPERVISOR

ING. JAN ODSTRČILÍK

BRNO 2013

ZDE VLOŽIT ORIGINAL ZADÁNÍ

Abstrakt:

Analýza snímků sítnice má důležitý význam, protože člověk získá kolem 90 % informací z okolí přes oči. Automatizace procesů analýzy zobrazení sítnice přispívá ke zlepšení efektivity lékařských retinálních vyšetření. Tato diplomová práce se zabývá automatickými metodami klasifikace snímků cévního řečiště retiny pořízených digitální fundus kamerou. Je prozkoumána a implementována metoda klasifikace cévního řečiště s použitím klasifikátoru na základě neuronových sítí, které se trénují a pak se testují na úsecích cév retinálního řečiště. Ve stručnosti je v této práci popsán anatomický pohled na sítnici, vlastnosti obrazových dat z digitální fundus kamery a metody klasifikace retinálních snímků. Poslední kapitola se zabývá hodnocením úspěšnosti klasifikace cévního řečiště automatickými metodami.

Klíčová slova:

Snímky sítnice, fundus kamera, extrakce parametrů, klasifikace, neuronové sítě.

Abstract:

Retinal image analysis plays a very important role, as human gets around 90% of environment information with the help of eyes. Automation of process of retinal image analysis promotes to improve the efficiency of retinal medical examinations. The following thesis is dedicated to automatic classification methods of retinal vascular system images obtained from a digital fundus camera. Vessel classification method using classifier on the base of neural networks, which is trained and then tested on the retinal vessel segments, is investigated and implemented. In this thesis anatomical retinal survey, properties of image data from digital fundus camera and retinal image classification methods are briefly described. The last chapter is devoted to the evaluation of efficiency of retinal vessel classification with automatic methods.

Key words:

Retinal images, fundus camera, extraction of parameters, classification, neural networks.

TEBENKOVA, I. *Klasifikace cévního řečiště na snímcích sítnice: diplomová práce.*
Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních
technologií, 2013. 58 s. Vedoucí diplomové práce je Ing. Odstrčilík Jan.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Klasifikace cévního řečiště na snímcích sítnice jsem vypracovala 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 neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne 23. května 2013

.....
podpis autora

Poděkování

Děkuji vedoucímu diplomové práce Ing. Odstrčilíku Janovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne 23. května 2013

.....
podpis autora

OBSÁH

Úvod	5
1. Snímky sítnice jako objekt zkoumání.....	7
1.1.1 Mikroskopická stavba	7
1.1.2 Makroskopická stavba	8
2. Rešerše současného stavu	17
3. Návrh metody.....	19
3.1 Přizpůsobená filtrace.....	22
3.2 Použití morfologických operací	24
3.3 Extrakce příznaků	27
4. Klasifikace.....	35
4.1 Úvod do neuronových sítí	35
4.2 Model perceptronu	38
4.3 Klasifikace Ho-Kashyap.....	35
5. Popis implementovaných funkcí	44
6. Výsledky a jejich diskuse	47
7. Závěr.....	52
8. Seznam použité literatury.....	54
9. Použité zkratky a symboly.....	58

Seznam obrázků

Obr.1.1: Anatomie oka.....	7
Obr.1.2:Principiální schéma fundus kamery.....	10
Obr.1.3: Fundus kamera.....	12
Obr.1.4:a) pravé oko RGB; b)levé oko RGB.....	13
Obr.1.5: Výřez snímku sítnice z fundus kamery.....	14
Obr.1.6: Problémy při klasifikaci tepen a žíl	15
Obr.1.7: a) Červená složka; b) Výřez z obrázku.....	16
Obr.1.8: a) Zelená složka; b) Výřez z obrázku.....	16
Obr.1.9: a) Modrá složka; b) Výřez z obrázku.....	16
Obr.3.1: Oblast zkoumání.....	20
Obr.3.2: Výřezy tepen G-složka.....	20
Obr.3.3: Výřezy žíl G-složka.....	21
Obr.3.5: Principiální blokové schéma použité metody.....	22
Obr.3.6: Výstupy základních etap zpracování přizpůsobené filtrace.....	24
Obr.3.7: Morfologická operace eroze.....	25
Obr.3.8: a) Binární verze snímku sítnice b) Výsledek použití morfologické operace eroze.....	25
Obr.3.9: Morfologická operace skeletonizace.....	26
Obr.3.10: a) Původní obrázek úseku cévy b) Výsledek použití morfologické operace skeletonizace.....	26
Obr.3.11: a) Místa vykreslení jasových profilů kolmo k tepně; b) Průměrný profil; c)Průměrný profil po aproximace.....	28
Obr.3.12: a) Místa vykreslení jasových profilů kolmo k žíle; b) Průměrný profil; c) Průměrný profil po aproximace	29
Obr.3.12: Příznak 1 (hodnota maximálního jasu).....	30
Obr.3.13: Příznak 2 (hodnota šířky cév, odpovídající 50% jasu).....	31
Obr.3.14: Příznak 3 (plocha pod grafem jasového profilu).....	31
Obr.3.15: Graf příznakového prostoru	32
Obr.3.16: Boxploty funkce pravděpodobnosti hustoty normálního rozložení.....	33

Obr.3.17: Boxploty a)Příznak 1; b) Příznak 2; c) Příznak 3.....	34
Obr.4.1: Model umělého neuronu.....	36
Obr.4.2: a)Jednoduchý perceptron s n vstupy, jedním výstupem z a prahem citlivosti neuronu θ ;	
b) Skoková přenosová funkce.....	39
Obr.4.3: Perceptron jako klasifikátor.....	40
Obr .5.1:Postup klasifikace s použitím algoritmu Ho-Kashyap.....	40
Obr. 6.1 a)Příklad vykreslení jasových profilů pro cevku v oblastí mezikruží;	
b) Průměrný jasový profil.....	46
Obr 6.2 a)Oblast zkoumaní;	
b) Příznak 1 (maximalní jas);	
c) Příznak 2 (šířka jasového profilu v 50% jas);	
d) Příznak 3(plocha pod grafem jasového profilu);.....	48
Obr.6.3 Výsledky klasifikace retinálních snímků cév databáze UBMI, FEKT s použitím algoritmu Ho-Kashyap	
a) snímek 01_h.jpg;	
b) snímek 02_h.jpg;	
c) snímek 03_h.jpg;	
d) snímek14_h.jpg;.....	50

Seznam tabulek

Tab.1: Technická specifikace digitální fundus kamery CANON CF-60 UVi.....	12
Tab.6.1: Průměrné chyby a jejich směrodatné odchylky pro klasifikaci cév podle jednotlivých příznaků nebo jejich kombinací.....	47
Tab. 6.2: Počet správně a nesprávně detekovaných cév na retinálních snímkach databaze FEKT UBMI, skupina «zdravé oči».....	51

Úvod

Analýza snímků sítnice má důležitý význam, protože člověk získá kolem 90 % informací z okolí přes oči. Rozvoj moderní zobrazovací techniky dává možnost rychle a efektivně získávat retinální snímky. Nicméně, dokonce zkušený lékař-oftalmolog musí dávat pozor na detaily snímků z toho důvodu, že počáteční stádia retinálních chorob jsou nevýrazná. K nejčastěji diagnostikovaným nemocem patří makulární degenerace, diabetická retinopatie, hypertenze a glaukom [35]. Odhalení patologických stavů v počátečním stádiu je zárukou maximálního odstranění patologických změn a dlouhodobé obnovy zrakové funkce.

V současné době je analýza sítnice aktuálním problémem, který se řeší pomocí počítačové techniky. Automatizace procesů analýzy zobrazení sítnice přispívá ke zlepšení efektivity lékařských retinálních vyšetření. Toto je velmi důležité z hlediska úspory času a rozpočtu zdravotnictví, kromě toho automatizace dává možnost realizovat objektivní kritéria výběru ohrožujících forem onemocnění a zjistit retinální choroby v počátečních stádiích.

Mezi úlohami automatického zpracování zobrazení retiny je možné definovat základní skupiny úloh:

1. Hodnocení kvality a předběžné zpracování zobrazení sítnice. Určení vhodnosti zobrazení pro analýzu. Nejčastějšími problémy jsou například pohybová neostrost nebo nevhodné nastavení parametrů fundus-kamery.
2. Segmentace objektů na retinálních snímcích. Například v souvislosti s automatickým rozpoznáváním a lokalizací optického disku, žluté skvrny a cévního řečiště můžeme zmínit práce [11], [21], [31]. Rozpoznáním a měřením vlastností vrstvy nervových vláken na sítnici se zabývají publikace [21], [36].
3. Vyhledání a hodnocení patologií [21].


Tato diplomová práce se zabývá klasifikací snímků cévního řečiště pořízených digitální fundus kamerou. Existuje řada přístupů a metod vedoucích k klasifikaci cévního řečiště ze snímků sítnice. Seznam nepoužívanějších metod klasifikace cévního řečiště z retinálních snímků lze nalézt v kapitole 2. V této práci je prozkoumána metoda klasifikace řečiště na základě neuronových sítí. Podrobný popis postupu je obsažen ve 3. kapitole. Vstupní informací je několik různých parametrů charakterizujících typ cévy (tepna nebo žíla) a extrahovaných z jasových profilů snímků sítnice. Neuronová síť

založená na perceptronu se trénuje na 70% náhodně vybraných vzorků cév retinálních snímků a pak se testuje na zbylých 30%. Po ukončení procesu učení a adaptace sítě, byl klasifikátor otestován na cévách retinálních snímků v určité oblasti zkoumání. Kapitola 4 obsahuje popis použitého algoritmu klasifikace. Posledním krokem je pokus implementace metody na snímky sítnice, hodnocení její efektivity a zhodnocení dosažených výsledků, což je uvedeno v 6. kapitole. Navržená metoda klasifikace cévního řečiště byla realizována na osobním počítači ve vývojovém prostředí MATLAB, s použitím reálných snímků dostupných na ÚBMI FEKT v Brně, pocházejících z oftalmologické ordinace MUDr. Tomáše Kuběny ve Zlíně.

1. Snímky sítnice jako objekt zkoumání

1.1 Anatomický pohled na sítnici , seznam nemocí

Sítnice (lat. retina) je vnitřní tenká vrstva oka obratlovců. Její hlavní funkcí je snímání a předzpracování světelných signálů přicházejících na sítnici skrze oční čočku [1].



Obr.1.1: Anatomie oka; zdroj: [4]

1.1.1 Mikroskopická stavba

Anatomicky se člení na deset vrstev: vrstva pigmentových buněk, vrstva čivých výběžků, zevní ohraničující membrána, vnitřní jádrová vrstva (tyčinky a čípky), zevní plexiformní vrstva, vnitřní jádrová vrstva (bipolární, horizontální a amakrinní buňky), vnitřní plexiformní vrstva, vrstva gangliových buněk, vnitřní ohraničující membrána, vrstva axonůgangliových buněk, přičemž čivé výběžky jsou nejdále od dopadajícího světla.

Funkce jednotlivých buněk

- *Pigmentové buňky* - pohlcují světlo, které již bylo zaznamenáno tyčinkami a čípkami a zabráňuje jeho zpětnému odrazu (jako je tomu u kůrovitých šelem), čímž zvyšuje ostrost vidění.

- *Tyčinky a čípky* - modifikované neurony se schopností reagovat na dopad světla. Tyčinky reagují i na slabé světlo, ale neregistrují barvy a neposkytují dostatečně ostrý obraz. Existují tři druhy čípků (jeden pro každou základní barvu), poskytují ostrý a barevný obraz, ale potřebují dostatečné osvětlení.
- *Bipolární buňky* - přepojení vzruchu z čivých buněk.
- *Horizontální buňky, amakrinní buňky* - asociační buňky propojující mezi sebou jednotlivé bipolární, případně gangliové buňky. Podílí se na předzpracování obrazu (proč je tomu tak, plyne z původu sítnice - viz níže).
- *Gangliové buňky* - buňky sbírající informace ze sítnice (je jich cca 10x méně než čivých buněk) a přeposílající informace dále do mozku. Soubor jejich axonů tvoří zrakový nerv [2].

1.1.2 Makroskopická stavba

Na sítnici jsou dobře zřetelné dva útvary – slepá skvrna neboli optický disk, kudy vystupuje zrakový nerv a vstupuje a. centralis retinae, která se tam i větví na své čtyři hlavní větve. Optický disk je důležitý bod při vyšetření oftalmoskopem - jestli je propadlý, tak je zvýšený nitrooční tlak (který může způsobit zelený zákal), jestli je naopak vystouplý, je zvýšený tlak nitrolebeční, což může být způsobeno mnoha patologickými procesy v lebce, které mohou být život ohrožující (nádor, hydrocephalus, epidurální krvácení). Druhým útvarem je takzvaná centrální jamka obsahující žlutou skvrnu. Žlutá skvrna je místem maximální ostrosti vidění, obsahuje pouze čípky a ostatní vrstvy sítnice jsou odsunuty stranou.

Sítnice dále obsahuje cévní systém, který zajišťuje zásobování tkáně kyslíkem a nezbytnými látkami. Větve arterie centralis představují jediné místo, kde lze stav cévního systému vyšetřit bez narušení integrity organismu – vyšetření tzv. očního pozadí (fundus) hraje proto významnou roli i z tohoto hlediska [1].

Onemocnění sítnice patří mezi nejzávažnější a často vedou ke ztrátě zraku. K nejvíce rozšířeným nemocem patří odchlípení sítnice, makulární degenerace, diabetická retonopatie. Sítnice může degenerovat, trpět různými dědičnými chorobami, onemocněním cév nebo záněty.

Odchlípení sítnice

Odchlípení sítnice je poměrně časté onemocnění, které většinou způsobuje trhлина v sítnici. Příznaky odchlípení sítnice snadno rozpoznáte. V okraji zorného pole

se objevují záblesky způsobené tahem sklivce za sítnici, rovněž padající saze či plovoucí smítka, což jsou krvinky z natržené cévy. V konečném stádiu se také objevuje tmavá clona, která postupně zrak zastíní. Vzniklé odchlípení sítnice je v každém případě nutné operovat co nejdříve, aby nedošlo k dalšímu zhoršení onemocnění.

Makulární degenerace

Makulární degenerace je onemocnění, které většinou spojujeme se stářím. Dochází k poruše žluté skvrny, což je oblast ve středu sítnice, která ovládá centrální zorné pole a umožňuje schopnost barevného vidění. V takzvané vlhké formě této nemoci vidí pacienti ve středu svého vidění šedé stíny nebo černé skvrny. Periferní vidění naopak většinou zůstává neporušené. Makulární degeneraci dnes ještě nelze úplně vyléčit. Při léčbě vlhké formy se snaží pomocí nitroočních injekcí potlačit růst nových cév.

Diabetická retinopatie

Diabetická retinopatie je nepříjemné onemocnění způsobené špatně léčenou cukrovkou. Postihuje sítnici oka a může vést až ke slepotě. Nadměrné množství glukózy v krvi ucpává a poškozuje jemné cévy, kterými je sítnice protkána. Onemocnění je nebezpečné zejména proto, že se u něho velmi dlouho neprojevují žádné příznaky a je bezbolestné, takže k jeho odhalení dochází až v pozdější fázi, kdy už ohrožuje náš zrak. Důležitá jsou proto pravidelná vyšetření u očního lékaře.

Ostatní nemoci sítnice

Sítnice může degenerovat, trpět různými dědičnými chorobami, onemocněním cév nebo záněty. Pacienty s onemocněním sítnice podrobně vyšetříme a doporučíme nejvhodnější způsob léčby [35].


1.2 Vyšetřování očního pozadí

Diagnostika nitroočních struktur a očního pozadí patří k základním typům vyšetření oka. V současné době se i v tom klinickém oboru výrazně uplatňují nové technologie a výpočetní technika.

Základní vyšetření očního pozadí, tzn. zadní části sklivce a sítnice, lze provádět v přímém obrazu - přímou oftalmoskopií pomocí oftalmoskopu. To je ruční opticko-mechanický přístroj opatřený vlastním světelným zdrojem, optickým systémem a otočnými kotouči se sadami korekčních skel.

Při nepřímé oftalmoskopii je oko vyšetřováno pomocí vyšetřovací oční lupy, +10 až 30 D. V prostoru mezi lupou a vyšetřujícím se vytvoří skutečný, převrácený a zvětšený obraz pozorovaného očního pozadí.

Nejdokonalejším optickým přístrojem ke sledování a dokumentaci stavu očního pozadí jsou retinální kamery. Jejich optický systém umožňuje korigovat i vysoké hodnoty ametropie (-35 D až +40 D) a intenzivní světelný zdroj dovoluje pořídit kvalitní fotografickou dokumentaci očního pozadí. Špičková zařízení jsou navíc vybavena CCD-kamerami pracujícími ve viditelné i infračervené oblasti umožňujícími počítačovou analýzu zaznamenaných snímků. Této možnosti je využíváno zejména při vyhodnocení výsledků fluorescenční angiografie. Zavedení digitálních fundus kamer ve vysoké míře podporuje diagnostiku různých onemocnění oka i kardiovaskulárního systému. Můžeme zmínit např. diabetickou retinopatii, makulární degeneraci, zelený zákal (glaukom). Principiální schéma fundus kamery je na obrázku



Obr.1.2: Principiální schéma fundus kamery (1 – zobrazovací jednotka; 2, 3, 4 – poziciční jednotka; 5 – operační panel pro lékaře; 6 – objektiv; 7 – počítač); zdroj: [31]

Fundus kamery jsou většinou vybaveny systémy pro automatické nalezení středu sítnice a systémy automatického ostření, které se provádí pomocí frekvenční analýzy snímaného obrazu hodnocením obsahu vysokých frekvencí. Dále obsahují systém automatického řízení intenzity osvětlení sítnice, kdy se vyhodnocují předchozí snímané obrazy, a intenzita osvětlení se upravuje na základě průměru jasu v těchto obrazech.

Vedle retinálních kamer se k vyšetření očního pozadí nyní využívají i laserové skenovací oftalmoskopy a retinografy. Tyto přístroje skenují povrch sítnice laserovým

paprskem. Tím je dosaženo vyšší rozlišovací schopnosti obrazu. Přístroj rovněž dokáže mapovat vyklenutí papily zrkového nervu. Tato informace je velmi cenná pro diagnostiku glaukomu. [3]

1.2.1 Fundus kamera CANON CF-60 UVi

Všechna obrazová data využita k analýze byla pořízena fundus kamerou CANON CF-60 UVi s vestavěným digitálním fotoaparátem CANON EOS-20D s nastaveným zorným polem FOV = 60°. Následující vlastnosti a technické specifikace byly převzaty od výrobce[4].

Základní vlastnosti

- Zobrazení FOV (*Field of View*) 30°, 40°, a 60°,
- možnost fluoresceinové angiografie (FA) – standard, 16
- možnost indocyaninové angiografie (ICG) – volitelné rozšíření,
- možnost pořízení snímku s červeným a modrozeleným filtrem,
- přesný zaostřovací systém pomocí „dělené čáry“ a „spot“,
- automatické nastavování filtrů při FA a ICG angiografii,
- režim snímání při úzké zornici SP,
- automatická expozice 35 mm barevné fotografie,
- automatické natáčení,
- možnost tisku pořízených snímků,
- vestavěný fotoaparát CANON EOS-20D (8,2 Mpix CMOS snímač).



Obr.1.3: Fundus kamera CANON CF-60 UVi; zdroj: [32]

Technická specifikace

Tab.1: Technická specifikace digitální fundus kamery CANON CF-60 UVi [4]


Zorné pole FOV	60°, 40°, 30°
Zvětšení u 35 mm filmu	1.7 x (60°), 2.5 x (40°), 3.4 x (30°)
Velikosti snímků	ø29 mm x 22 mm (35 mm filmu) ø75 mm x 57 mm (Polaroid filmu)
Minimální průměr čočky	ø4 mm
Pracovní vzdálenost	45 mm
Rozsah nastavitelných 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

1.3 Popis dat pro analýze

Jako vstupní data pro analýzu byly primárně použity snímky sítnice pořízené fundus kamerou s vestavěným digitálním fotoaparátem CANON EOS-20D s 60° FOV (Field of View) z databáze dostupné na ÚBMI, FEKT VUT v Brně, získané z oční ordinace MUDr. Tomáše Kuběny ve Zlíně. Databáze ÚBMI, FEKT VUT v Brně je rozdělena na tři skupiny z pohledu výskytu různého onemocnění. Při analýze byly použity snímky bez patologií.

Na obrázku 1.4 jsou poskytnuty barevné snímky pravého a levého oka. Z hlediska anatomie oka při oftalmologickém zkoumání má oční dno červenou barvu. Intenzita zabarvení závisí na množství retinálního (v sítnici) a choroidálního (v cévně

skořápce) pigmentu. Na červeném pozadí se vyčleňují disk zrakového nervu, žlutá skvrna a cévy sítnice. Disk zrakového nervu má tvar bledě červeného kruhu nebo oválu o průměru 1,5 mm. V centru disku v místě východu hlavních cév vyznačuje se jamka. Z centra disku zrakového nervu vychází hlavní tepna v doprovodu stejnojmenné žíly. Tepna a žíla se dělí na dvě hlavní větve probíhající nahoru a dolů.




a)

b)

Obr.1.4:a) pravé oko RGB; b) levé oko RGB

Retina obsahuje komplikovaný cévní systém. Nehledě na fakt, že se skládá z jednoduchých vzorů, tak se mohou projevovat morfologické změny a to vzhledem k věku nebo nemoci, například cévní okluze, která zvyšuje délku žil, zvýšený krevní tlak, který zúží tepny nebo diabetes, který vytváří nové krevní cévy (neovaskularizace)[1].



Obr.1.5: Výřez snímku sítnice z fundus kamery

Na obrázku 1.5 je vyznačena žíla (označená jako 1) a tepna (2). Vizualně lze zpozorovat, že artérie mají jasnější barvu, než žíly. Důvodem k tomu je různé složení krve v tepnách a žilách. Tepny obsahují krev nasycenou kyslíkem. V žilách je krev, která má kysličník uhličitý a produkty vznikající při látkové výměně. Z obrázku je

zřejmé, že žíly jsou širší, než tepny. Tlak v retinálních artériích je mnohem vyšší, než v žilách proto jsou stěny žil širší. Centrální reflex se projevuje více u tepen (na obrázku světlá čára ve středu tepny).

Existují čtyři hlavní příznaky, které se používají pro rozpoznání tepen a žil, jimiž jsou [5]:

1. Tepny jsou tenčí než vedlejší žíly (poměr průměrů tepen a žil sítnice se rovná 2:3).
2. Tepny sítnice jsou méně krouceny, než žíly [7].
3. Tepny mají světlejší barvu než žíly.
4. Centrální reflex (odraz světla z vnitřních povrchů je širší u tepen než u žil).
5. Tepny a žíly se obvykle střídají vedle optického disku před rozvětvením. To znamená, že vedle optického disku je jedna tepna, která je blízko dvou žil a vedle jedné žíly jsou dvě tepny.[6]

Uvedené příznaky často dávají dostačující informaci, aby úspěšně klasifikovaly cévu jako tepnu nebo žilu. Nicméně v mnohých případech to nestačí z následujících příčin [6]:


- Jestli kvalita snímků není dostatečná (obvykle po stranách snímku) – nedochází k centrálnímu reflexu.

- Cévy po stranách snímku jsou tmavší v důsledku efektu zastínění (nehomogenní osvětlení snímku). Tady jsou tepny a žíly podobné, což vede k chybám při klasifikaci cév.

- Šířka cév není při klasifikaci užitečná, protože se mění. Maximální je poblíž optického disku a minimální po stranách snímku.


- Střídání tepen a žil platí jenom poblíž optického disku. Když se začínají větvit, tak se dvě větve jedné cévy rozmísťují jedna blízko druhé.

Obrázek 1.6 ukazuje tyto čtyři problémy. Horní levý: po stranách snímku jsou cévy tmavší a centrální reflex není vidět; horní pravý: šířka cév není při klasifikaci užitečná; dolní levý: příklad čtyř velkých cév, kdy rozdíl mezi tepnami a žilami není odlišen; dolní pravý: střídání tepen a žil není platné kvůli rozvětvení artérie.



Obr.1.6: Problémy při klasifikaci tepen a žil; zdroj: [2]


Všechny snímky v databázi použité při analýze jsou RGB s 24 bitovou barevnou hloubkou (*Truecolor*) a používají kompresi standardu JPEG. Rozlišení snímků je 3504 x 2336 pixelů. Vstupní data použita k analýze představují datové pole o rozměrech $M \times N \times 3$. Jedná se o tři stejně velké matice reprezentující jednotlivé komponenty RGB obrazu (R – červená, G – zelená, B – modrá). Rozdělení RGB obrazu na barevné komponenty ukazují obrázky 1.7, 1.8 a 1.9. Na obrázcích 1.7b), 1.8b) a 1.9b) jsou zobrazeny výřezy, které ukazují, jak vypadají tepny a žíly v jednotlivých složkách v oblasti poblíž optického disku.



Obr.1.7: a) Červená složka; b) Výřez z obrazku (žíla označená jako 1, tepna jako 2)



Obr.1.8: a) Zelená složka; b) Výřez z obrázku(žíla označená jako 1, tepna jako 2)



Obr.1.9: a) Modrá složka; b) Výřez z obrázku(žíla označená jako 1, tepna jako 2)

Na základě získaných obrázků je třeba si všimnout, že zelená a modrá složka budou nejpřijatelnější pro další analýzu snímků sítnice z pohledu klasifikace cévních struktur na tepny a žíly. V zelené složce je rozdíl jasu tepen a žil (jejich kontrast) největší.

2. Rešerše současného stavu

Ve sféře medicínské diagnostiky a výzkumu chorob je třeba provádět detailní analýzu skupiny medicínských zobrazení. Tato analýza obvykle požaduje měření nebo vypočítání určitých parametrů v závislosti na strukturách zahrnovaných do snímků. Tyto úlohy jsou realizované odborníky, a to ručně. Je zřejmé, že proces analýzy trvá příliš dlouho a je citlivý k subjektivním chybám. Proto je nutné použití více důvěryhodných automatických metod a zlepšování už existujících metod v oboru medicínských zobrazení.

V literatuře existuje řada metod pro detekce retinálních cévních struktur. V referenci [8] se Gaussova křivka používá pro modelování průřezů cév a přizpůsobená filtrace provádí detekce cévních struktur. Prezentovaný přístup s použitím přizpůsobených filtrů (angl. Matchedfiltering) principiálně využívá korelace mezi lokální oblastí v obrazu, potencionálně obsahující segment struktury, který obsahuje snímek a filtrační maskou, která je navržena jako aproximace typického segmentu analyzované struktury Gaussovou křivkou. V práci je použito 12 různých šablon pro získání úseků cév ve všech možných směrech. Stejný postup přizpůsobené filtrace je základem práce [9]. Jsou definovány celkem 3 dvourozměrné filtrační masky (filtry) na základě rozdělení cév podle šířky na tenké, středně široké a široké cévy. Ke zjištění šířek cévních struktur byly vytvořeny jasové profily, popisující prostorovou distribuci jasu napříč cévou. Jedná se o závislosti jasu (intenzity) na prostorové souřadnici v obraze. Výsledkem provedené filtrace jsou parametrické obrazy, které představují výsledek konvoluce vstupního obrazu a přizpůsobených filtrů s maskou. Největší odezvu ve výsledném obrazu budou mít hrany, které jsou orientované ve směru masky. Dále, článek [10] obsahuje popsané automatizované metody detekce obrysu cévního řečiště ze snímků očního pozadí. Cévní segmentace se provádí na základě lokálních a globálních parametrů. Výsledek přizpůsobené filtrace, získaný ze součástí cévního řečiště, je normalizován a kvantován do 8 bitů pro každý pixel. Pak pomocí zvýšení hodnoty prahu se analyzují oblasti obrázku a rozhoduje se, jestli tato oblast opravdu patří k úseku cévy nebo ne. Posledním krokem je segmentace cévního systému a srovnání s výsledky segmentace 20 snímků, udělaných ručně.

Reference [11] představuje novou metodu modelování, založenou na jednoduché detekci hran na základě filtrace typu Laplacian a nastavení prahu. Model zahrnuje velké

spektrum vlastností cévního systému jako délka, poměr délka-šířka, centrální reflex. Morfologická operace uzavření je použita pro detekci centrálního reflexu.

Jiná skupina metod využívá vlnkovou transformaci a pixelovou klasifikaci. V práci [12] jsou návrhy modelů s použitím filtru typu Gabor pro cévní detekce. Transformace pomocí těchto filtrů je zvláštním případem rychlé vlnkové transformace. Impulsní odezva je definována součinem harmonické funkce a Gaussovy funkce. Je vhodná pro detekce hran cévních struktur. Použití bank filtrů typu Gabor s různými frekvencemi a směry je vhodné pro extrakce parametrů cévního systému.

Další skupina metod je založena na přístupu, vycházejícím z trasování cév z předem určeného bodu. Jde o automatický proces hledání centrálních cévních bodů ('semínek') v průřezu cévy po celé její délce. Metoda je vhodná k hodnocení cévního průměru retinálních snímků. Gaussova funkce se používá pro modelování distribuce stupňů šedi v průřezu cévy a takovým způsobem může být definována číselná hodnota průměru. Technika trasování je založena na parametrech modelované distribuční křivky intenzity. Pro každý průřez zahrnuje hodnoty cévních průměrů. Takovým způsobem může být definována střední hodnota průměrů po délce cévy, což je vhodné pro další analýzu cévních struktur[14].

Bohužel, většina z uvedených metod nebere ohled na kontextuální informace z okolí cévních bodů pro definování orientačních bodů cévního řečiště. Tato informace může být vyjádřena pomocí sousedních bodů nebo cév a způsobí detekce reálných struktur a spojení retinálního stromu. Na seznamu literatury jsou uvedeny výzkumy, které se snaží tento problém vyřešit. Práce prezentovaná v [15] řeší tento problém použitím centrální cévní linie pro detekce a klasifikace příznakových bodů. Jiná metoda navržená v [16] označuje místa překřížení cévních úseků jako semínka pro sledování cévní centrální linie a klasifikuje příznakové body v závislosti náhleh od překřížení. Autoři článku [17] popisují postup extrakce cévní struktury na základě metody trasování. Metoda potřebuje předchozí postup pro detekce příznakových bodů, aby se neztratilo spojení v místech křížení cév po etapě trasování. Metoda, nabízená v [18] používá malé okénko pro analýzu celého skeletu cévního řečiště. V referenci [19] je morfologická struktura cévního řečiště extrahována a analyzována pro detekce uzlových bodů. Práce [5] se zabývá detekcí příznakových bodů a následně provedenou klasifikací detekovaných bodů do dvou tříd: bifurkace nebo křížení. Cévní řečiště je segmentováno ze snímků očního pozadí. Dalším krokem je získání skeletu ze segmentovaného

obrázku, ve kterém jsou detekovány příznakové body. V závěru jsou tyto příznakové body klasifikovány podle lokální analýzy a topologických map.

Algoritmy, představené v práci [21] realizují ohodnocení kvality snímků, vyrovnání intenzity jejich osvětlení, segmentace cév, nervového systému zrakového disku a také tmavých a světlých oblastí žluté skvrny na snímcích očního pozadí. Nejčastějším problémem při analýze zobrazení je nejasnost vyvolaná pohybovými artefakty nebo špatným nastavením ohniskových parametrů. Pro definování úrovně nejasností je použita analýza šířky cév. Na začátku se hledají hranice cév s největší hodnotou gradientu, dalším krokem je vykreslení cévních profilů. Předběžná fáze analýzy zahrnuje vyrovnání intenzity osvětlení, barevnou normalizaci a zvýšení kontrastu. Analýza detekce cévního řečiště se skládá z etap:

1. Postupné použití morfologických operací otevření a zavření s kruhovými elementy o průměru v rozsahu od 1 do dvounásobku maximální šířky cév. Pak se ze získaného zobrazení odečte původní. Hodnota maximální šířky cév se ukládá ručně.
2. Použití filtru typu Gabor se 4 měřítky ($1/4$, $1/2$, $3/4$ a 1 od maximální hodnoty šířky cév) a v 6 směrech. Výsledkem filtrace jsou maximální odpovědi filtrů Gabor v každém pixelu.
3. Vyhledání množství počátečních bodů příhodných pro následující segmentace cév.
4. Segmentace, která spočívá v iteračním rozšíření množství počátečních bodů cév pomocí strukturního elementu, jehož tvar se přizpůsobuje danému zobrazení.


Neuronové sítě jsou základem detekce pro některé modely. Pro cévní struktury organismu člověka mohou být vytvořeny různé typy klasifikátorů na základě neuronových sítí. Například v [13] se klasifikátor skládá z vícevrstvého okénka neuronové sítě typu feed-forward, které je klasifikováno na základě jasové informace. Neuronová síť byla vytrénována pomocí algoritmu. V práci jsou popsány různé konfigurace neuronových sítí pro zlepšení efektivity procesu segmentace cév. Pro řešení určité úlohy musí být systematicky analyzovány faktory, zahrnující topologie, trénovací skupinu a počáteční váhy. Článek [37] popisuje metodu klasifikace tepen a žil ze snímků fundus kamery. Práce se zabývá získáním příznaků z jasových profilů, odlišujících typy cév a analýzou obrovské variability parametrů cév. Jako vstupní data byly použity segmentované retinální snímky. Byly extrahovány příznaky cév v oblasti kolem optického disku. Metoda byla otestována na 448 retinálních snímcích databáze. Výsledkem je efektivita použité metody, což znamená, že pro 80% snímků je chyba klasifikace kolem 30%.

3. Návrh metody


Návrh navržené metody je zobrazen na obrázku. V této kapitole je krátce popsán postup použité metody. Jsou zde vysvětleny jednotlivé kroky zpracování.

Jako vstupní data pro analýzu byly primárně použity snímky sítnice pořízené fundus kamerou s vestavěným digitálním fotoaparátem CANON EOS-20D s 60° FOV (Field of View) z databáze dostupné na ÚBMI, FEKT VUT v Brně, získané z oční ordinace MUDr. Tomáše Kuběny ve Zlíně. Databáze ÚBMI, FEKT VUT v Brně je rozdělena na tři skupiny z pohledu výskytu různých onemocnění. Při analýze byly použity snímky bez patologií.


Ve fázi předzpracování bylo načteno 8 RGB snímků zdravých očí z databází a byla udělána řada výřezů cév, které se nachází v oblasti analýzy, poblíž optického disku. Rozměr zvolených výřezů je 41 x 41 pixel. Byly definovány dvě základní skupiny výřezů cév: tepny (160 výřezů) a žíly (160 výřezů). Toto rozdělení bylo uděláno podle subjektivního pohledu na cévy, představené na původních snímcích. Příznaky odlišující tepny a žíly jsou uvedeny v kapitole 1.3.



Obr.3.1: Oblast zkoumání



Obr.3.2: Výřezy tepen G-složka



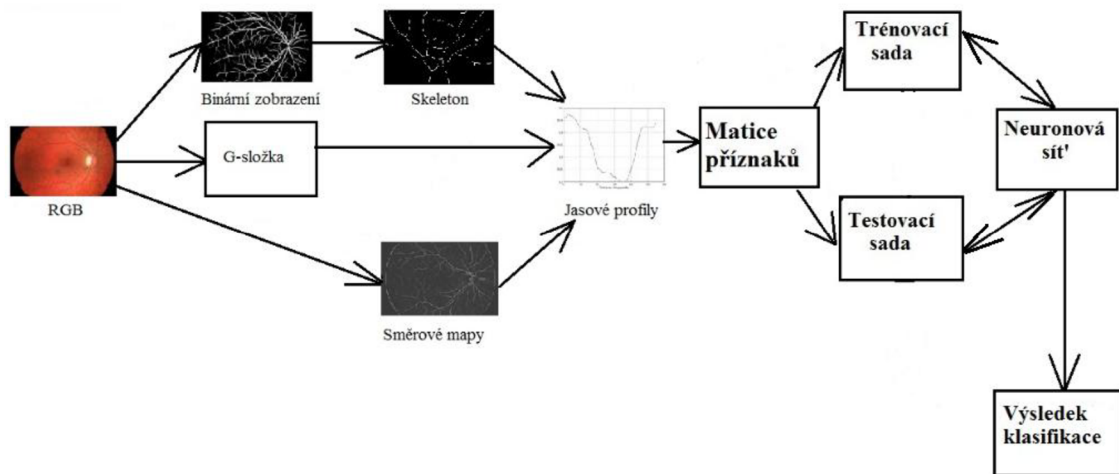
Obr.3.3: Výřezy žil G-složka

Dalším krokem bylo načtení binární verze původních obrázků, a jejich směrových map, které odpovídají zvoleným výřezům. Směrové mapy jsou výsledkem přizpůsobené filtrace, což je popsáno v 3.1.2. Z binární reprezentace výřezů původních RGB obrázků je získán skeleton použitím řady morfologických operací. Skeleton představuje binární zobrazení cévního řečiště, přitom tloušťka cév skeletonu je jeden pixel. Spojením se směrovými mapami je možné zjistit směr každého pixelu, který se nachází ve skeletonu.

Další fáze metody je extrakce příznaků, které jsou získány z jasových profilů. Jasové cévní profily popisují prostorovou distribuci hodnot jasu napříč cévou. V každém bodu skeletonu ve zkoumaných výřezech je známý směr, a kvůli tomu byl každý jasový profil vykreslen kolmo k úseku určité cévy. Z řady jasových profilů jsou spočítány tři příznaky, které byly zapsány do jediné matice. Tato matice je vhodná pro další analýzu.

Prezentovaný přístup segmentace cévního řečiště pomocí neuronových sítí je založen na použití lineárního klasifikátoru Ho-Kashyap. Základem je model perceptronu. Učení je základní vlastností neuronových sítí. Proces učení a adaptace potřebuje přítomnost trénovací množiny, která neuronové síti předkládá vzory charakterizující daný problém. Do trénovací množiny je vybrána matice příznaků, která zahrnuje dvě základní klasifikační třídy (tepny a žíly). Síť byla vytrénována na 70% výřezů cév. Byla zkoumána klasifikace na základě jednotlivých příznaků a také jejich různých kombinací. Po ukončení procesu učení na vstup neuronové sítě přichází testovací sada. Testovací sada se skládá z parametrů cév 30% výřezů. Na rozdíl od trénovací sady, v testovací sadě už není definováno určité třídění cévních skupin na tepny a žíly. Úkolem neuronové sítě je klasifikace cév na výstupu do dvou skupin s použitím parametrů, získaných během procesu trénování. V závěrečné fázi byla použita metoda implementována na retinální snímky databáze FEKT, ÚBMI. Výsledkem analýzy jsou vykreslené parametrické obrazy, ve kterých různé typy cév

definované na základě klasifikace pomocí neuronové sítě, se odlišují barevně. Efektivita použité metody je hodnocena číselně.



Obr.3.5: Principiální blokové schéma použité metody

Dále je každá etapa analýzy popsána podrobně.

3.1 Přizpůsobená filtrace

Přizpůsobená filtrace patří k etapě předzpracování. V této diplomové práci byly použity hotové směrové mapy jako výsledky přizpůsobené filtrace, vypracované ve výzkumu [9]. Teoretické základy dané metody jsou uvedeny dále.

Přizpůsobená filtrace je jedním z efektivnějších nástrojů, který se používá v číslicovém zpracování signálů. V prostorové oblasti filtrace obrazového signálu je představená jako 2D konvoluce původního obrazu $f(x, y)$ a filtrační masky $h(x, y)$. To může být popsáno vztahem:

$$g(x, y) = f(x, y) * h(x, y) \quad (3.1)$$

přičemž x a y jsou prostorové souřadnice

V diskretní oblasti je možné vyjádřit pomocí vztahu:

$$g(i; k) = f * h \mid (i; k) = h * f \mid (i; k) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} f(i-m, k-n)h(m, n) \quad (3.2.)$$

kde $f(i,k)$ je vstupním obrazem, $h(i,k)$ je konvoluční maska. Konvoluční matice se posouvá po obrazu a výsledkem jsou výstupní hodnoty – lineární kombinace vstupních hodnot pod konvoluční maskou.

Metoda přizpůsobené filtrace je založena na výsledné odezvě vstupního obrazu na dvourozměrný filtr neboli masku, která je navržena podle profilu objektu v původním obraze. Tato odezva vzniká diskrétní dvourozměrnou konvolucí filtru se vstupním obrazem. Odezva filtru je maximální v oblasti, kde se bude profil masky nejvíce shodovat s profilem pozorované lokální oblasti.

Přizpůsobený filtr je generován na základě klasifikace cév podle šířky. Jasové profily tenkých a středně širokých cév byly aproximovány jednoduchou Gaussovou křivkou, definovanou vztahem [22]:

$$h(x) = -e^{\frac{-x^2}{2\sigma^2}} \quad (3.3.)$$

kde x představuje vektor o zvolené délce. Pro jednotlivé hodnoty vektoru x tak dostaneme vektor h , jehož hodnoty představují vzorky 1D impulsní charakteristiky přizpůsobeného filtru.

Pro široké cévy byla provedena aproximace Gaussovou křivkou vzhledem k projevu centrálního reflexu [23].


$$h(x) = A_1 e^{\frac{-x^2}{2\sigma_1^2}} - A_2 e^{\frac{-x^2}{2\sigma_2^2}} \quad (3.4.)$$

kde parametr A_1 – výška profilu široké cévy a σ_1 – šířka poloviny profilu široké cévy v polovině jeho maximální výšky. Druhá část vztahu představuje aproximaci centrálního reflexu s parametry A_2 – výška centrálního reflexu a σ_2 – šířka poloviny centrálního reflexu v polovině jeho maximální výšky.

Dvourozměrné filtrační masky dostaneme roztážením jednorozměrných aproximací průměrných jasových profilů pro jednotlivé typy cév do prostoru ve směru osy y na délku, u které se předpokládá, že segment cévy nezmění svou orientaci. Tímto způsobem dostaneme 3 typy 2D filtračních masek $h(x,y)$ - pro tenké, středně široké a široké cévy.

Popsaným postupem získáme masky přizpůsobených filtrů pro jednotlivé typy cév orientované ve směru 0° . Cévy v obraze však mohou být orientovány v různých směrech, proto je potřeba provést rotaci základních masek do 12 různých směrů (0° - 165° , s krokem 15°). Touto cestou získáme celkem 36 filtračních masek přizpůsobených

nejen šířce segmentu cévy, ale i jeho orientaci. Ty postupně aplikujeme na vstupní obrázek, čímž dostaneme 12 odezví a ty pak váhově sečteme, čímž dostaneme výslednou odezvu. Parametrické obrazy odezví s použitím vhodného prahování jsou převedeny do binární verze. Na obrázku 3.3 jsou reprezentovány výstupy základních etap zpracování [9].



Obr.3.6: Výstupy základních etap zpracování přizpůsobené filtrace: a) originální RGB obraz; b) celkový parametrický obraz pro tenké cévy; c) konečný výsledek segmentace; zdroj: [9]

3.2 Použití morfologických operací.

Morfologické operace se původně používaly jako metody zpracování u binárních obrazů, kde sloužily k odstranění falešných prvků v obraze a také poskytovaly základní analýzu velikosti, tvaru a počtu objektů. V dnešní době moderní všeobecné morfologické metody tvoří širokou třídu nelineárních metod, použitých nejenom pro binární ale i pro vícerozměrná šedotónová data. Ty umožňují nové zajímavé způsoby zpracování a analýzy zobrazení. Zobecnění původních metod zpracování binárních dat pro šedotónové snímky je aktuální kvůli teoretickému rozvoji.

Většina morfologických transformací představuje transformace vstupem a výstupem, které jsou obrazy a proto jsou považovány za metodu zpracování obrazu. Nicméně výstupní obraz je obvykle modifikován a tím může být považován za parametrický obraz - protože ty jsou často značně zjednodušené verze, popisující vstupní obraz; z toho důvodu patří morfologické metody k analytickým.


V analýze jsou použity morfologické operace eroze a skeletonizace.

Binární eroze stanoví pro každou pozici (i, k) v prostoru binární odpověď na položenou otázku, jestli maska pokrývající obraz s počátkem umístěným v (i, k) odpovídá sadě f ve smyslu, že pod všemi jedničkami masky jsou jedničky obrazu?

Pokud označíme operace eroze $E_B(\dots)$ s maskou B , vstupní (nebo výstupní) sadu X (nebo Y), pozice (i,k) jako x , soubor masek jako B , a soubor masek posunutých tak, aby počátek byl umístěn v x jako B_x , výstupní sada obrazů může být vyjádřena pomocí vzorce:


$$Y = E_B(X) = x \mid B_x \subseteq X \quad (3.5.)$$

Eroze představuje průnik posunutých bodových množin. Na obrázku je znázorněná operace eroze s bodovou množinou X a strukturním elementem B . Křížkem je označen počáteční bod, který odpovídá pozici $(0;0)$.



Obr.3.7: Morfologická operace eroze; zdroj: [33]


Binární eroze zruší vstupní obraz – některé hraniční pixely jsou smazány, což vede ke zmenšení velikosti původního obrazu. Tyto změny jsou ireverzibilní, protože malé objekty a tenké výčnělky se nemohou spojit se strukturním elementem a jsou úplně odstraněny. Tímto způsobem eroze odstraňuje šum a nespojitosti. [24]



Obr.3.8: a) Binární verze snímku sítnice b) Výsledek použití morfologické operace eroze

Při zpracování obrazu existuje morfologická operace, která se jmenuje skelet nebo prostřední osa. Jde o binární zobrazení, které reprezentuje strukturu, vypočítanou pomocí morfologických operátorů.

Z matematického pohledu můžeme popsat skelet $S(Y)$ jako množinu bodů – středů kružnic, které jsou obsaženy v objektu Y a dotýkají se hranice Y alespoň ve 2 bodech. Na obrázku je znázorněná operace skeletonizace. Objekt Y představuje v tomto případě obdélník, ale existují i další formy v závislosti na analyzovaných strukturách v obrazu.



Obr.3.9: Morfologická operace skeletonizace; zdroj: [33]

Existují dva typy morfologických skeletů:

- Skelet, který je definován operací morfologického otevření, ze kterého je možné rekonstruovat původní obraz. Takto získaný skelet může být složen z čar tlustších než jeden bod.
- Často se skelet nahrazuje množinou, zpracovanou sekvenčním homotopickým zpracováním [33].



a)

b)

Obr.3.10: a) Původní obrázek úseku cévy b) Výsledek použití morfologické operace skeletonu

3.3 Extrakce příznaků

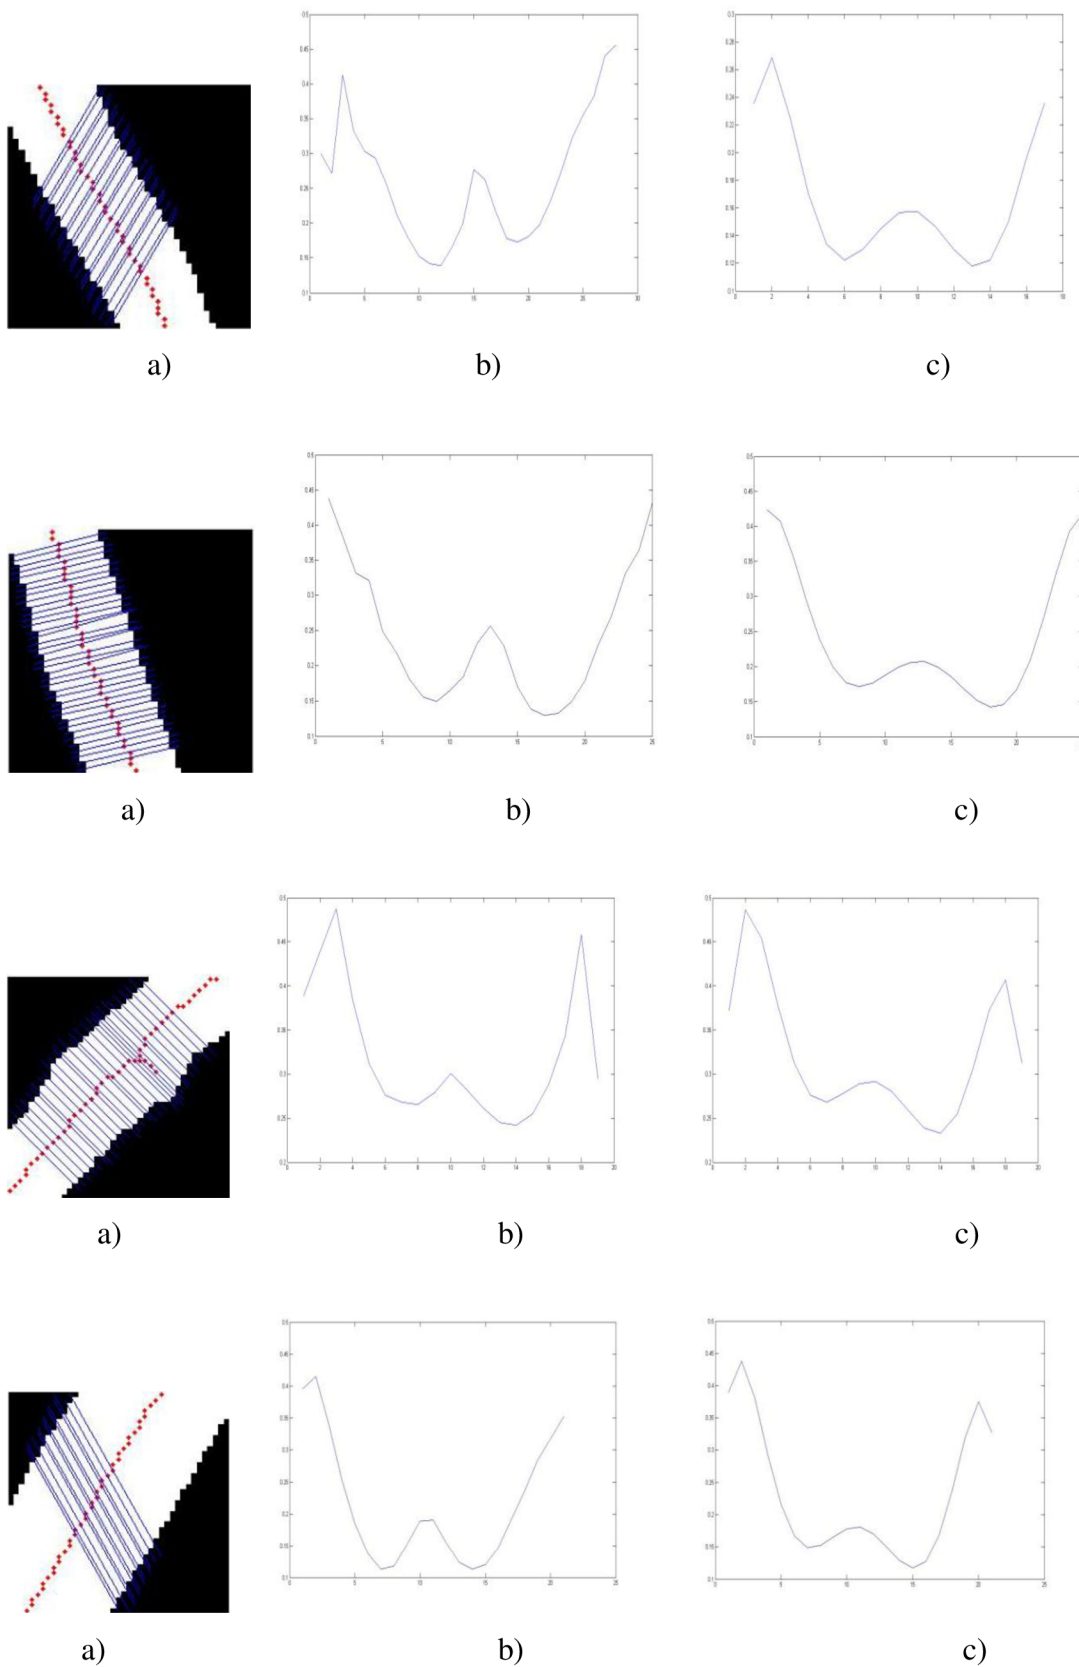
Retina obsahuje komplikovaný cévní systém. Úlohou této diplomové práce byla extrakce parametrů cévního systému z retinálních snímků z fundus-kamery. Cílem je vytvoření klasifikátoru, který by automaticky zjistil, jestli určitá céva patří k tepnám nebo žilám. V kapitole 1.3 jsou popsána vstupní data pro analýzu. Je evidentní, že tepny a žíly cévního řečiště můžeme popsat pomocí sady hodnot parametrů. Patří k nim tloušťka cév, hodnoty jasu, projev centrálního reflexu, což se projevuje na snímcích jako bílá čára a to je odraz světla z vnitřních povrchů cév při snímání, zakřivení cév. Na základě těchto parametrů je možné provést následující klasifikaci.

Vykreslení jasových profilů.

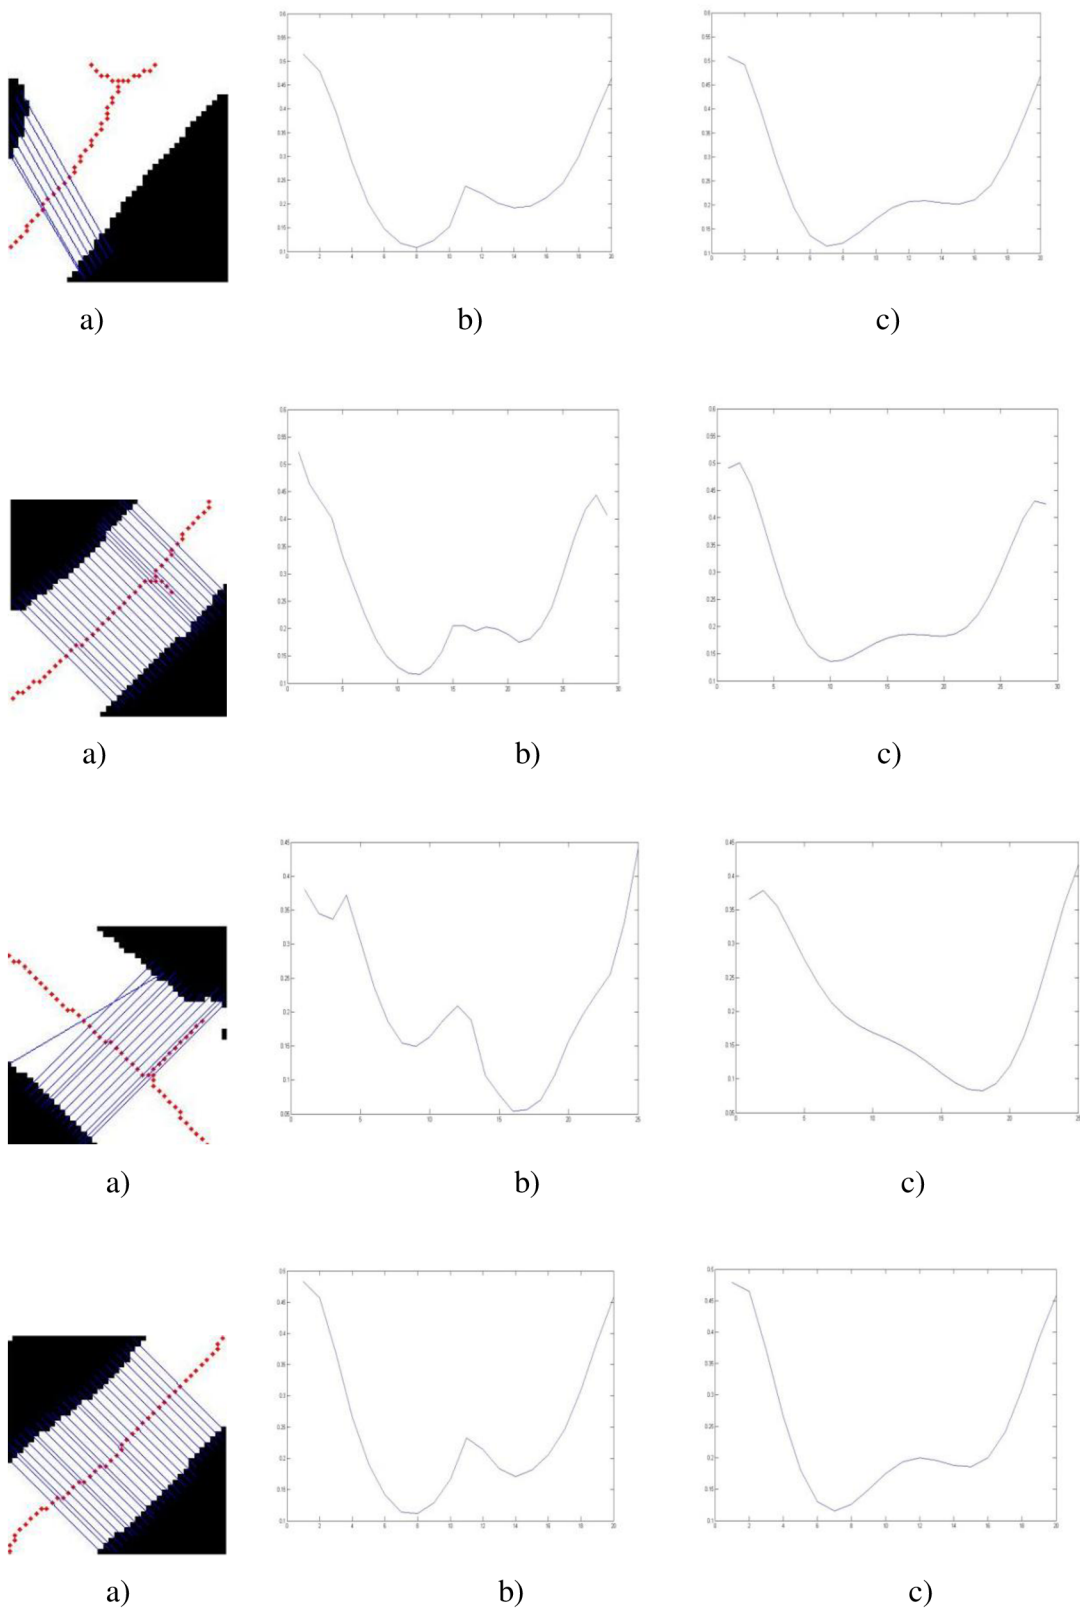
Jasové cévní profily představují prostorovou distribuci hodnot jasu napříč cévou. Jde o graf závislosti jasu (intenzity) na prostorové souřadnici v obraze. Při vytváření jasových cévních profilů byla zkoumána oblast ve vzdálenosti jednoho optického disku od jeho středu. Nejjasnější rozdíl mezi tepnami a žilami je znatelný právě v této oblasti. Proto byla vybrána oblast, která se rovná průměru optického disku. Profily se snímaly z různých tepen a žil přítomných ve zkoumané oblasti. Tyto profily byly získány z G složky, protože je nejvhodnější pro analýzu (viz. kapitola 1.3). Pro délku každého úseku cév, který patří do zkoumané oblasti, se procházel bod po bodu skeletonu s určitým krokem a kolmo ke každému zkoumanému bodu cévy byl vykreslen jasový profil. Cévní profily byly naměřeny v místě vyznačeném modrou úsečkou. Z řady jasových profilů úseku cévy pak byl vypočítán střední výsledný profil, který byl aproximován s použitím polynomů podle metody nejmenších čtverců. Polynom se zadává podle vzorce [28]:

$$f(x) = a_0x^N + a_1x^{N-1} + a_2x^{N-2} + \dots + a_nx + a_n \quad (3.6)$$

Délka elementu polynomu použitého pro aproximaci se rovná 6, a to je optimální hodnota, aby důležitá informace z jasového profilu nebyla ztracena.



Obr.3.11: a) Místa vykreslení jasových profilů kolmo k tepně; b) Průměrný profil;c) Průměrný profil po aproximace



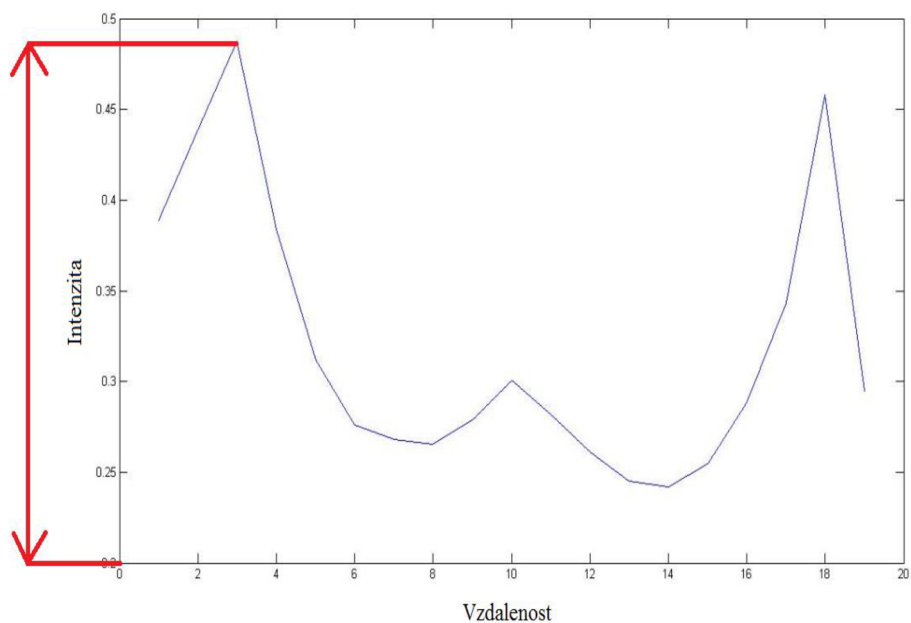
Obr.3.12: a) Místa vykreslení jasových profilů kolmo k žilě; b) Průměrný profil;c) Průměrný profil po aproximace

Z profilů je patrné, že výskyt cévy se v obraze projeví lokálním poklesem intenzity v dané oblasti. Hodnoty jsou normovány a jsou v rozsahu [0;1], když se šířka mění v rozsahu [15-20]. Z profilů na obrázku 3.11 je vidět i vliv centrálního reflexu, který se projevuje jako mírné lokální navýšení intenzity uprostřed cévy. Tyto obrázky představují profily tepen s centrálním reflexem, který způsobuje podstatně větší lokální navýšení intenzity. Na obrázcích 3.12 jsou zobrazené žíly, ve kterých není centrální reflex téměř rozpoznatelný.


Z naměřených jasových profilů vyplývá základní členění cév na cévy s centrálním reflexem - to jsou tepny, a na cévy bez centrálního reflexu - žíly (čtvrtý příznak, viz kapitola 1.3). Tepny s centrálním reflexem lze dále rozdělit na tepny, kde v profilech centrální reflex tvoří výrazné lokální maximum a na cévy, u kterých centrální reflex existuje, ale není příliš výrazný. To znamená, že plocha pod grafem se také liší v závislosti na přítomnosti centrálního reflexu. To je jeden z parametrů, který je použit při analýze.

Na profilech tepnám odpovídá vyšší úroveň jasů, než žilám (třetí příznak, viz kapitola 1.3). Z grafů byla získána hodnota, odpovídající maximálnímu jasů, který je druhým příznakem.


Na některých obrázcích je vidět šířkový rozdíl mezi tepnami a žilami, ale tento rozdíl není příliš velký. Závisí na vzdálenosti určitého úseku cévy od optického disku. Z grafu byla vypočítána hodnota šířky cév, odpovídající 50% jasů, který je třetím příznakem použitým při analýze.



Obr.3.12: Příznak 1 (hodnota maximálního jasů)




Obr.3.13: Příznak 2 (hodnota šířky cév, odpovídající 50% jasů)



Obr.3.14: Příznak 3 (plocha pod grafem jasového profilu)

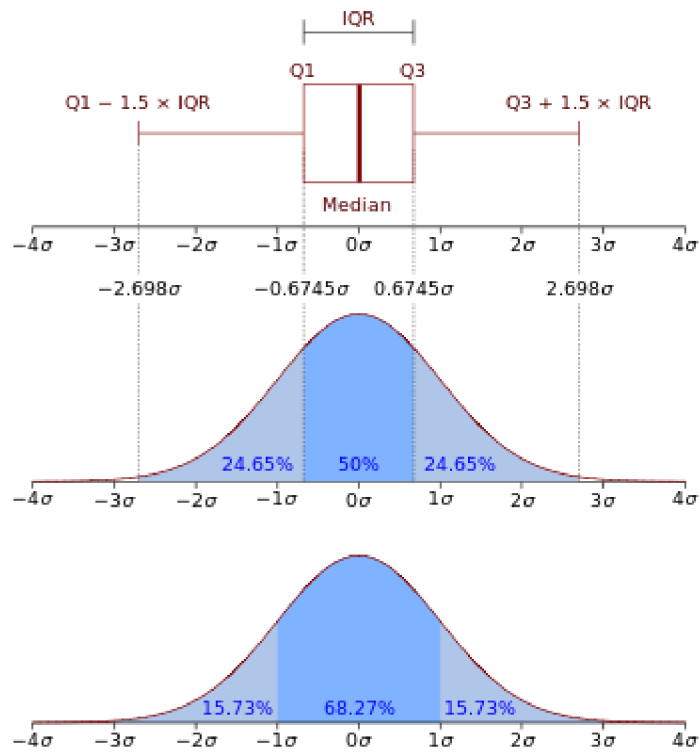
Pro vizualizaci všech třech spočítaných příznaků bylo použito zobrazení na grafu a boxploty.



Obr.3.15: Graf příznakového prostoru (červené křížky odpovídají tepnám, zelené křížky odpovídají žilám)


Tři osy grafu odpovídají jednotlivým příznakům. Každý bod grafu reprezentuje konkrétní profil určitého úseku tepny nebo žíly, ze kterého byly vypočítány příznaky. Přičemž červenými křížky jsou označeny tepny, zelenými - žíly. Z grafu je vidět, že v některých oblastech se množina bodů tepen překrývá s množinou bodů žil. Pro detailní rozbor jednotlivých příznaků byly vytvořeny speciální diagramy - boxploty.

Boxplot (angl. box-and-whisker diagram) je vhodným instrumentem pro grafické vyjádření skupin číselných dat a vyjadřuje statistickou informaci z těchto dat. Typický boxplot zahrnuje 5 parametrů: minimum ze vzorků, nižší kvartil (Q1), medián (Q2), vyšší kvartil (Q3), a maximum ze vzorků. Analýza různých částí boxplotů pomáhá ohodnotit míru rozptylu, zkreslení a rozsah dat. Mohou být zobrazeny jak horizontálně, tak vertikálně [25].




Obr.3.16: Boxplot funkce pravděpodobnosti hustoty ($N(0,1\sigma^2)$) normálního rozložení, zdroj [20]

Na obrázcích jsou vykresleny boxploty pro jednotlivé příznaky. Hodnota maximálního jasu, vypočítaná z jasových profilů je označena jako příznak 1, šířka cév odpovídající 50% hodnotě jasu je označena jako příznak 2, příznak 3 odpovídá ploše pod grafem jasového profilu. Po horizontální ose každého z boxplotu 1 označuje tepny, 2-žíly.



a)

b)



c)

Obr.3.17: Boxploty a) Příznak 1; b) Příznak 2; c) Příznak 3

Střední a extrémní hodnoty příznaku 1 a 3 se hodně liší, když u 2 příznaku jsou v malém rozsahu. Z boxplotu je zřejmé, že při další analýze jsou vhodné příznaky 1 a 3. U 2. příznaku se parametry tepen a žil moc neodlišují. Střední hodnota parametrů a jejich maximální a minimální hodnoty se nachází ve stejném úzkém rozsahu, což může vést k chybám při klasifikaci tepen a žil. Příčinou tomu mohou být profily nevhodné k analýze nebo chyby ze směrových map. Ale při klasifikaci budou prozkoumány všechny tři příznaky a také jejich různé kombinace.

4. Klasifikace

Ke klasifikaci rozsáhlých souborů dat, včetně dat snímaných z biologických objektů, se s výhodou využívají i expertní systémy. Jedná se o formu adaptivních učících se klasifikátorů aplikovaných na vhodné programové prostředí. Expertní systém se skládá z báze znalostí, báze dat a tzv. inferenčního mechanismu – programu, který s těmito bázemi definovaným způsobem pracuje. Základními problémy všech expertních systémů jsou kódování expertních znalostí reprezentovaných pravidly, míra spolehlivosti využívaných informací a nutnost neustálé adaptace znalostí.

Kvalitativní posun v procesech klasifikace expertními systémy nastal aplikací neuronových sítí. Umělé neuronové sítě jsou koncepčně řešeny podobně jako biologické neuronové sítě. Využívají distribuované paralelní zpracování informací celou neuronovou sítí. Znalosti jsou ukládány prostřednictvím síly vzájemných vazeb mezi jednotlivými neurony. Propojení mezi neurony vedoucí ke správnému výsledku jsou zesilována, propojení vedoucí k chybnému výsledku jsou zeslabována.

Učení (bez učitele) je základní vlastností neuronových sítí. Ke klasifikaci není třeba definovat algoritmus práce s daty. Proces učení, adaptace, využívá tzv. trénovací množinu, která neuronové sítí předkládá vzory charakterizující daný problém. Do trénovací množiny je třeba vybrat reprezentativní vzory po každou klasifikační třídu. Data musí být rovněž statisticky testována na normalitu a separabilitu.

Základními parametry neuronových sítí jsou synaptické váhy mezi neurony, strmost a tvar přenosových funkcí, prahové hodnoty neuronů. Neuronová síť je definována svou topologií, tzv. počtem vstupních a výstupních neuronů, počtem vnitřních vrstev neuronů. Zásadní význam při aplikaci má i užití programové prostředí a struktura databáze signálů [26].


4.1 Úvod do neuronových sítí

Neuronová síť je jeden z výpočetních modelů používaných v umělé inteligenci. Jejím vzorem je chování odpovídajících biologických struktur. Umělá neuronová síť je struktura určená pro distribuované paralelní zpracování dat.

Neuronové sítě mají své opodstatněné použití v případech, kdy při řešení daného problému buď není možné matematicky popsat všechny vztahy a souvislosti, které ovlivňují sledovaný proces, nebo v případech, kdy se nám sice podaří exaktní

matematický model sestavit, ale je tak složitý, že případná algoritmizace úlohy není možná. Rovněž také zjednodušující matematické popisy nemusí vést k žádoucím výsledkům. Jde zejména o složité a nelineární systémy.

Skládá se z umělých (nebo také formálních) neuronů, jejichž předobrazem je biologický neuron. Neurony jsou vzájemně propojeny a navzájem si předávají signály a transformují je pomocí určitých přenosových funkcí. Neuron má libovolný počet vstupů, ale pouze jeden výstup.



Obr.4.1: Model umělého neuronu; zdroj: [30]

Model umělého neuronu je popsán vztahem:

$$Y = S\left(\sum_{i=1}^N (\omega_i x_i) + \Theta\right) \quad (4.1.)$$

kde x_i jsou vstupy neuronu; ω_i jsou synaptické váhy; Θ je nastavený práh; $S(x)$ je přenosová funkce neuronu; Y jsou výstupy neuronu.

Velikost vah ω_i definuje uložení zkušeností do neuronu. Čím je vyšší hodnota, tím je daný vstup důležitější. V biologickém neuronu práh Θ označuje prahovou hodnotu aktivace neuronu. Když součet součinů vstupů a synaptických vah neuronů je menší než práh, neuron je v pasivním stavu. Výběr přenosové funkce závisí na určité úloze, typu neuronu a typu neuronové sítě.

Cílem učení neuronové sítě je nastavit síť tak, aby dávala přesné výsledky. V biologických sítích jsou zkušenosti uloženy v dendritech. V umělých neuronových sítích jsou zkušenosti uloženy v jejich matematickém ekvivalentu - váhách. Učení neuronové sítě rozlišujeme na učení s učitelem a učení bez učitele. Fáze učení neuronové sítě bývá nazývána adaptivní. Po naučení neuronové sítě je síť ve fázi vybavování.

Existují různé typy klasifikace neuronových sítí. Například, neuronové sítě můžeme rozdělit na tři skupiny: asociativní paměti, klasifikátory a aproximátory.

- *Asociativní paměti* jsou sítě, které odpovídají vzorem, který je asociován (logicky spojen) se vstupním vzorem. Podle druhu asociace rozdělujeme paměti na autoasociativní (vstupní i výstupní vzor je podobný, tyto sítě lze použít k rozpoznávání poškozených vzorů) a heteroasociativní (vstup a výstup je různý, na daný podnět si vybavíme něco jiného, co se vstupem souvisí). Nejznámější asociativní paměť je *Hopfieldova síť*.

- *Klasifikátory* jsou sítě, které rozpoznají vstupní vzor a zařadí ho do vybrané třídy. Na výstupu je tato třída zastoupena např. logickou jedničkou na příslušném výstupu, zatímco ostatní výstupy jsou nulové. Úlohou klasifikátorů je tedy zařadit vzor na základě podobnosti. Typickým zástupcem tohoto druhu sítí je např. *Hammingova síť*.

- *Aproximátory* jsou sítě, jejichž funkce spočívá ve vytvoření vlastního vnitřního modelu na základě vstupních informací, který aproximuje skutečný systém. Tato vlastnost dovoluje síti predikovat události. Aproximátory je samozřejmě možné použít jako klasifikátory, ale je to zbytečně mohutný nástroj. Nejznámějším zástupcem tohoto druhu sítí je *vícevrstvá perceptronová síť*, pro kterou se někdy používá označení *síť BP* (z angl. backpropagation, síť se zpětným šířením chyby).

Kromě výše zmíněného rozdělení lze sítě ještě dělit na sítě s učitelem a bez učitele.

Učení s učitelem

Představuje v praxi nejběžnější způsob učení. Jak již bylo uvedeno, jedná se o učení s učitelem, tudíž hledaná transformační funkce umělé neuronové sítě je vždy dána dvojicí hodnot. A to hodnotou vstupní proměnné x_i na straně jedné, a k ní požadovaným výstupem y_i daný učitelem na straně druhé. Tyto požadované výstupní hodnoty se během učícího procesu porovnávají se skutečným výstupem sítě y_i (skutečný výstup vznikne jako odezva neuronové sítě na daný vstupní signál). Přitom během procesu učení dochází k modifikaci vah, spojení za účelem dosažení co možná největší shody mezi skutečným a požadovaným výstupem. Patří k nim např. *Hopfieldova síť*.

Učení bez učitele

Tento typ učení je založen na schopnosti sítě rozeznat na vstupech stejné nebo podobné vlastnosti a třídit tak vektory podle těchto vlastností. Tyto vektory se shlukují do shluků. Neuronové sítě jsou poskytovány pouze informace o vstupech. Účelem sítě je

hledat minimální vzdálenost od vzoru. Mezi sítě bez učitele řadíme např. *Kohonenovu síť*.

Dole jsou heslovitě uvedeny některé aplikace neuronových sítí:


- klasifikace - zařazení vstupního (příznakového) vektoru do jedné z daných tříd
- shlukování - vytváření skupin podobných vstupních vektorů
- vektorová kvantifikace - přiřazení vstupu nejbližšímu vzoru
- funkční aproximace
- predikce
- identifikace systémů - aproximace chování systému
- optimalizace [27]

V praxi se neuronové sítě používají mimo jiné i pro rozpoznávání a kompresi obrazů nebo zvuků, předvídání vývoje časových řad (např. burzovních indexů), někdy dokonce k filtrování spamu. V lékařství slouží k prohlubování znalostí o fungování nervových soustav živých organismů. Například perceptronová síť vznikla původně jako simulace fyziologického modelu rozpoznávání vzorů na sítnici lidského oka.

4.2 Model perceptronu

Perceptron je nejjednodušším modelem dopředné neuronové sítě. Skládá se pouze z jednoho neuronu. Perceptron byl vynalezen v roce 1957 Frankem Rosenblattem. Přes úvodní nadšení bylo později zjištěno, že jeho užití je velmi omezené, neboť je možné ho použít pouze na množiny, které jsou lineárně separovatelné. Jeho rozšířením je vícevrstevný perceptron, který má již mnohem širší možnosti použití.

Jednoduchým *perceptronem* se nazývá v podstatě jednotlivý neuron, popř. jednovrstvá síť s dopředným šířením. Patří k typu učení s učitelem. Neuronová aktivační funkce představuje znaménkovou funkci, popř. jednotkový skok. Perceptron v nejjednodušší podobě je binární klasifikátor, který mapuje vektor vstupů $x=[x_1, x_2, \dots, x_n]$ na výstupní hodnoty $f(x)$



Obr.4.2: a) Jednoduchý perceptron s n vstupy x (jimž přísluší váhy w_i), jedním výstupem z a prahem citlivosti neuronu θ ; b) Skoková přenosová funkce

$$f(x) = \begin{cases} 1 & \text{pro } \omega \cdot x + b > 0 \\ 0 & \text{jindy} \end{cases} \quad (4.2.)$$

kde ω je vektor vah, b je konstanta. Celkový podnět neuronu udává vážený součet $\xi = \sum_{i=1}^N \omega_i x_i - \theta$ Tento celkový podnět bývá označován jako potenciál neuronu.

Na potenciál reaguje perceptron výstupní odezvou $Z = S(\xi)$, kde S je tzv. přenosová funkce. Je-li přenosová funkce ve tvaru funkce skokové, pak se jedná o již výše zmíněný perceptron fungující jako binární klasifikátor. Skoková přenosová funkce vrací pro vstup menší než daná mez nulu, pro větší vrací jedničku. $f(x) = 0$ pro $x < \theta$ a $f(x) = 1$ pro $x \geq \theta$. Dalšími typy přenosových funkcí jsou například přenosové funkce sigmoidy, hyperbolické tangenty či radiální báze. [28]

Učení perceptronu probíhá pomocí tréninku s učitelem, kdy je perceptronu nejdříve předložena množina příkladů se správným chováním, učící pravidlo následně nastaví váhy a práh tak, aby došlo k přiblížení výstupu sítě cíli. Rozhodovacích hranic může být nekonečný počet.

Učení má následující fáze:

- inicializace úvodních hodnot - nastavení vah na náhodné hodnoty, nastavení prahu
- předložení vstupního vektoru síti - vstupní vektor je předložen síti a pomocí funkce je zjištěna jeho výstupní hodnota

$$Z = Z(S) = S\left(\sum_{i=1}^N \omega_i x_i - \theta\right) \quad (4.3.)$$

- vyhodnocení klasifikace vstupního vektoru - výstupní hodnota zjištěná sítí je porovnána se správnou výstupní hodnotou - pokud se nerovnejí, je potřeba přikročit k adaptaci vah, jinak je možné pokračovat k dalšímu kroku
- adaptace vah a prahu
- váhy perceptronu jsou adaptovány dle následujícího pravidla:

$$\omega^{nový} = \omega^{starý} + e \cdot p \quad (4.4.)$$


přičemž $e = t - a$ je chyba perceptronu, t je zjištěná hodnota výstupu, a je očekávaná hodnota výstupu. Konkrétně je-li vyhodnocen vstup jako 0, přestože má být vyhodnocen jako 1, pak novou váhu získáme přičtením vektoru tohoto vstupu k původní váze a naopak, je-li vyhodnocen vektor jako 1, i když má být vyhodnocen jako 0, pak získáme novou hodnotu vah tak, že od staré váhy odečteme vektor vstupu. Pokud je vektor vyhodnocen správně, pak váhy neupravujeme a pokračujeme k vyhodnocení dalšího ze vstupů v tréninkové množině.

- úprava prahu perceptronu:

$$b^{nový} = b^{starý} + e \quad (4.5.)$$

- opakování kroků 2-4 pro všechny tréninkové vstupy [29]

Perceptron se používá hlavně jako klasifikátor pro lineárně separovatelné obrazy. Výsledek klasifikace je na obrázku.



Obr.4.3: Perceptron jako klasifikátor; zdroj:[34]

Počet vstupů do sítě udává dimenzi prostoru. Pro jeden vstup ($N=1$) bude obrazovým prostorem přímka, pro dva vstupy dostaneme rovinu, atd. Předpokládejme dva vstupy. Počet neuronů v jednovrstvém perceptronu bude udávat počet hraničních

přímek rozdělujících rovinu. Čím více bude neuronů a tedy i hraničních přímek, tím přesněji můžeme vymežit danou oblast.

4.3 Klasifikace Ho-Kashyap

V diplomové práci byl použit postup klasifikace typu Ho-Kashyap [30]. Základem Ho-Kashyap postupu je perceptron. Perceptron a procedury relaxace slouží ke zjištění třídících vektorů, když je skupiny vzorků možné lineárně oddělit, ale netýkají se nelineárních úloh. Do algoritmu jsou zahrnuty uvedené proměnné:

J_s funkce kritéria nebo váhová funkce,

$\eta(k)$ proměnný přírůstek,

$y(k)$ je skupina analyzovaných objektů,

Y je matice, do které je zapsána sekvence vzorků,

k -počet opakování algoritmu,

a - rozdílový vektor,

b -vektor mezí

Pokud máme případ skupin lineárně oddělených, znamená to, že existují \hat{a} a \hat{b} a pro ně platí: $Y\hat{a} = \hat{b} > 0$, přičemž každá komponenta \hat{b} je kladnou veličinou. Pokud rozdílový vektor a a vektor mezí b patří k funkci kritéria, jsou vybrány libovolně a mění se, minimální hodnota J_s se rovná nule, a vektor a při kterém je dosaženo minimum, je rozdílovým vektorem. Pro minimalizaci J_s , je potřeba analyzovat funkce gradientu. Gradient ve vztahu k vektoru a je vyjádřen vzorcem:

$$\nabla_a J_s = 2Y'(Ya - b) \quad (4.6)$$

i gradient ve vztahu k vektoru b je dán vzorcem:

$$\nabla_b J_s = -2(Ya - b) \quad (4.7)$$

Pro libovolnou hodnotu vektoru b platí:

$$a = Y^\dagger b \quad (4.8)$$

kde Y^\dagger je pseudoinverzní matice Y .

Čímž dosáhneme, že $\nabla a J_s = 0$ a minimalizování J_s během jednoho kroku a to s ohledem na vektor a . Přičemž vektor b definujeme pomocí kladných hodnot. Pravidlo mezi má tvar:

$$b(k+1) = b(k) - \eta \frac{1}{2} [\nabla b J_s - |\nabla b J_s|] \quad (4.9)$$

Pomocí rovnic [1] a [2] dostaneme pravidlo Ho-Kashyap pro minimalizaci $J_s(a, b)$:

$$\begin{cases} b(1) > 0 \text{ jinak} \\ b(k+1) = a(k) + 2\eta(k)e^+(k) \end{cases} \quad (4.10)$$

Kde $e(k)$ je chybový vektor, $e^+(k)$ je kladná část chybového vektoru

$$e^+(k) = \frac{1}{2} (e(k) + |e(k)|) \quad (4.11)$$

a $a(k) = Y^\dagger b(k)$, $k=1, 2, \dots$

Pokud budeme považovat b_{\min} za minimální kritérium konvergence a $\text{Abs}[e]$ bude označovat kladnou část e , pak je možné algoritmus Ho-Kashyap vyjádřit jako:

1. begin initialize $a, b, \eta(\cdot) < 1$, kritéria b_{\min}, k_{\max}
2. do $k \leftarrow (k + 1)$
3. $e \leftarrow Y a - b$
4. $e^+ \leftarrow \frac{1}{2}(e + \text{Abs}[e])$
5. $b \leftarrow b + 2\eta(k) e^+$
6. $a \leftarrow Y^\dagger b$
7. if $\text{Abs}[e] \leq b_{\min}$ then return a, b and exit
8. until $k = k_{\max}$
9. Print "NO SOLUTION FOUND"
10. End

Vzhledem k tomu, že vektor $a(k)$ je úplně definován vektorem mezi $b(k)$, algoritmus Ho-Kashyap slouží k vypočítání posloupnosti vektorů mezi. Počáteční vektor $b(1)$ je kladný při podmínce $\eta > 0$, všechny následující vektory $b(k)$ jsou kladné. Když jsou všechny komponenty vektoru $b(k)$ záporné, $b(k)$ se nemění, a proto nebude řešení nalezeno. V případě když $e(k) = 0$ algoritmus taky nemá řešení. Pokud $e(k) \leq 0$, skupiny není možné lineárně oddělit.

V diplomové práci byl použit algoritmus Ho-Kashyap, který trénuje lineární klasifikátor. Proces učení, adaptace, využívá tzv. trénovací množinu, která neuronové síti předkládá vzory charakterizující dvě skupiny cév (tepen a žil). Do trénovací množiny je třeba vybrat reprezentativní vzory pro každou klasifikační třídu. Do trénovací sady jsou zahrnuty vzorky tepen a žil s rozměrem 41x41 pixel (viz obr.3.2 a 3.3), získané z několika obrázků databáze ÚBMI, FEKT VUT v Brně. Příznaky, popsané v kapitole 3.3 jsou uspořádané do matic. Tyto matice příznaků jsou vstupní data pro klasifikaci trénovací sady. Během analýzy byly prozkoumány jednotlivé příznaky cév a taky jejich různé kombinace. Síť se trénuje na 70% náhodně vybraných výřezech tepen a žil z retinálních snímků a pak se testuje na ostatních 30% s použitím metody křížkové validace. Tato metoda spočívá v tom, že vstupní sada dat je rozdělena na podmnožiny této sady. Jedna podmnožina slouží jako testovací sada, zbylé podmnožiny slouží jako trénovací sada. Klasifikátor natrénuje model na trénovací sadě a pomocí testovací sady testuje přesnost a výkonnost tohoto modelu. Tento proces se několikrát opakuje, pokaždé s jinou podmnožinou tvořící trénovací a testovací sadu. Pro další analýzu je vypočítán vektor vah, který definuje váhy pro příznaky ze vstupních dat. Po skončení procesu učení a adaptaci neuronové sítě byly spočítány průměrné hodnoty chyb a směrodatné odchylky. Výsledky jsou zahrnuty do tabulky 2 (viz. kapitola 6).

5. Popis implementovaných funkcí

Etapy použité metody, uvedené v kapitole 3, jsou implementovány pomocí programového prostředí MATLAB. Konečným výsledkem programu je možnost automatického rozpoznání tepen a žil. Použitá metoda klasifikace cévního řečiště byla vytvořena na osobním počítači TOSHIBA Satellite L 300, procesor 2,2 MHz, 2GB operační paměti DDR2a operačním systémem Windows 7. Program byl napsán v prostředí MATLAB verze 7.9.0. (R2009b). V kapitole 4 jsou uvedeny části programů a použité funkce, které se týkají jednotlivých etap zpracování.

Výběr vzorku pro analýzu cévy

Vstupem je jeden z retinálních snímků skupiny zdravých očí. Funkce uloží čtvercové 'vzorky' z retinálního snímku do 3D matice. Poloha vzorku se kliká myší pomocí příkazu 'ginput ', a také se ukládá spolu se vzorkem. V programu je zadána poloviční velikost okna, to znamená, že pro výřezy 41x41 se zadává velikost okna 20. To je optimální velikost výřezů pro další analýzu. V každém čtverci je úsek jedné cévy bez křížení a bifurkace. Po skončení programu se výsledky ukládají do stejnojmenného souboru typu 'mat'. Tepny se ukládají do souborů typu mat.'vzorky_tepny ', žíly do 'vzorky_zily' .

Analyze_tepny/ Analyze_zily

Jsou to dva stejné úseky programu pro analýzu skupiny tepen a žil. Jako vstupní data byly načteny soubory 'Healthy images_originalni data', což jsou původní retinální snímky, 'Healthy segmentace' – binární verze původních retinálních snímků, 'Mapy_smeru' což je výsledkem přizpůsobené filtrace (viz kapitola 3.1) a 'vyrezy_tepny' nebo 'vyrezy_zily', které jsou výsledkem předchozího úseku programu. Binární verze výřezů byly podrobeny morfologickým operacím eroze a skeletonizace. Pak v každém bodě skeletů úseků cév představených ve výřezech, byla vykreslena řada kolmic, tzv. jasových profilů. Kolmice byla zadána pomocí rovnice přímky, která má tvar:

$$Y=k(x)+b \quad (5.1)$$

kde k úhlový koeficient, určující sklon přímky $k = \operatorname{tg}(\Theta)$

Úhel byl definován s použitím směrových map, každý bod těchto map, který má hodnoty v rozsahu $[0,12]$, což odpovídá úhlovému rozsahu $[0^\circ,165^\circ]$. V případě úhlů, pro které tg není definován, tj. úhly 90° a 270° , byly výřezy otočeny o 90° . Profily jsou označeny jako modré čáry kolmo k určité cévě. Z řady profilů každého úseku cévy

byl vypočítán průměrný profil s použitím funkce aproximace 'polyfit' a 'polyval'. Z průměrných profilů byly extrahovány příznaky: maximální hodnota jasu, šířka profilu v 50% jasu a plocha pod grafem. Všechny příznaky byly uloženy do matic.

Plott

Tento úsek programu slouží k vytváření prostoru příznaků, které jsou uloženy do matic. Vstupem jsou matice jednotlivých příznaků. Výstupem je 3D graf, přičemž každá osa odpovídá určitému příznaku. Na grafu jsou tepny označeny červenými křížky, žíly - zelenými křížky.

Boxplot

Tento program slouží k vykreslení, tzv. boxplotů (viz kapitola 3.3). Vstupem jsou matice jednotlivých příznaků. Výstupem jsou diagramy, které jsou vhodným nástrojem pro grafické vyjádření skupin číselných dat a vyjadřují statistickou informaci z těchto dat. Pro každý příznak vykreslen zvláštní boxplot.

Ho-Kashyap

Program vytváří funkce 'Ho-Kashyap' (viz. kapitola 4.3)

Klasifikace perceptron

Tento program vytváří algoritmus Ho-Kashyap pro klasifikace cév. Do trénovací sady jsou přiřazovány matice příznaků tepen a žil. Vektor 't' slouží pro definování příslušnosti vzorků k dané třídě. Matice příznaků tepen je označena jako 0, matice příznaků žil jako 1. Proces trénování se provádí na 70% vzorků s použitím metody křížkové validace. Klasifikátor natrénuje model na trénovací sadě a pomocí testovací sady, která se skládá ze zbývajících 30% vzorků (testovací sada je označena jako 'p_test'), testuje přesnost a výkonnost tohoto modelu. Tento proces se opakuje sto krát, pokaždé s jinou podmnožinou tvořící trénovací a testovací sadu. Po skončení procesu učení a adaptaci neuronové sítě byly spočítány průměrné hodnoty chyb a směrodatné odchylky, které jsou zapsány do tabulky 2.

Mezikruží

Tento úsek programu je použit pro vykreslení dvou kružnic menšího a většího průměru pro definování oblasti zkoumání s použitím funkce 'plot_circle'. Vstupy: x a y souřadnice středu kružnice, rádius a intervaly, což jsou body x souřadnice uspořádané rovnoměrně. Výstupem je matice [M x 2], která obsahuje pozice souřadnic vykreslené kružnice. Analyzovaná oblast je mezikruží poblíž optického disku, kde je možné provádět další etapy analýzy cév. Vstupem jsou originální retinální snímky a jejich binární reprezentace. Klikáním myši pomocí příkazu 'ginput' do středu a do okrajů

optického disku dostaneme požadovanou oblast. Dále se provádí segmentace jednotlivých cév v oblasti: z bodu $kord_x$ a $kord_y$ vedly přímky do středu optického disku (x_OD , y_OD). Pak byly vypočítány směrnice a následně úhly těchto přímek. Následně byla vytvořena maska, která byla natáčena o příslušný úhel (podle úhlu přímky) a násobená mezikružím. Takovým způsobem jsou odděleny jednotlivé cévy mezikružím. Dalším krokem bylo použití morfologických operací eroze a otevření pro ztenčení a čištění nespojitých úseků cév a skeletonizace cév. Souřadnice skeletonu byly uloženy do matic. V podprogramu 'priznaky' byla vykreslena pro každý bod skeletonu kolmice, jejíž sklon byl určen mapami směrů. Z každé kolmice byl vykreslen jasový profil, který zahrnuje všechny pixely cévy, odpovídající binární verzi pozorované oblasti, a 2 pixely černého pozadí z každé strany od rozhraní cévy. Z řady jasových profilů byl udělán průměrný jasový profil. Po jeho aproximaci byly vypočítány a zapsány do matice tři příznaky. Pomocí podprogramu 'klasifikace' se provedla klasifikace podle algoritmu Ho-Kashyap, přičemž do trénovací sady byly zahrnuty všechny příznaky, získané ze vzorků tepen a žil ('Analyza_tepny' a 'Analyza_zily'). Ty jsou označeny jako matice p_norm na obrázku 5.1. Skupina tepen je označena jako 0, skupina žil jako 1, čemuž odpovídá vektor t . V testovací sadě byly označeny příznaky cév mezikružím, na obrázku 5.1 jsou označeny jako matice p_test . Výstupem programu je vektor $test_out$, určující rozdělení testovací sady do dvou skupin tepen a žil.

$$\begin{array}{c}
 \begin{bmatrix}
 P1 & P2 & P3 & 0 \\
 - & - & - & 0 \\
 - & - & - & 0 \\
 P1 & P2 & P3 & 1 \\
 - & - & - & 1 \\
 - & - & - & 1 \\
 \hline
 p_norm & & & t
 \end{bmatrix}
 =
 \begin{bmatrix}
 P1 & P2 & P3 & x \\
 - & - & - & x \\
 - & - & - & x \\
 - & - & - & x \\
 - & - & - & x \\
 - & - & - & x \\
 \hline
 p_test & & & test_out
 \end{bmatrix}
 \end{array}$$

Obr.5.1: Postup klasifikace s použitím algoritmu Ho-Kashyap

6. Výsledky a jejich diskuse


Příznaky, použité v neuronových sítích jako vstupní data, byly uplatněny v klasifikaci. Efektivita klasifikace byla ohodnocena v tabulce 2, kam jsou zahrnuty parametry průměrná chyba klasifikace a směrodatná odchylka. Rozbor těchto parametrů ukazuje že všechny tři příznaky jsou vhodné pro další implementace metody na snímky sítnice. Na základě tabulky 2 lze posoudit že jednotlivý příznak zvlášť nestačí pro další analýzu. Přesto je vhodné použití různých kombinací příznaků, nebo celé skupiny 3 příznaků. Nejlepší výsledek ukazuje kombinace prvního příznaku, což je hodnota maximálního jasů, a třetího příznaku, což je plocha pod grafem jasového profilu.

Tab.6.1: Průměrné chyby a jejich směrodatné odchylky pro klasifikaci cév podle jednotlivých příznaků nebo jejich kombinací

Příznaky	Průměrná chyba [%]	Směrodatná odchylka [%]
P1	49,9667	10,8504
P2	25,7	7,6877
P3	32,7667	8,8008
P1P2	28,6333	8,4765
P1P3	8,8	5,01
P2P3	16,5667	7,2853
P1P2P3	8,9	4,852

V závěrečné fázi byla použita metoda implementována na retinální snímky zdravých očí databáze FEKT, ÚBMI. Pro analýzu byla vybrána oblast mezikruží kolem optického disku vzhledem k tomu, že v této oblasti mají pozorované cévy stabilní šířku, jsou rovné a nekříží se. Pro definování pixelů, které patří k určité cévě, byla vytvořena binární maska, která se otáčela s určitým krokem v oblasti mezikruží, a takovým způsobem byly odděleny jednotlivé cévy v mezikruží. Dále byl použit stejný postup, který je popsán v kapitole 3. Tento postup zahrnuje načtení binární verze původních obrázků a jejich směrových map, které odpovídají zvolené oblasti. Směrové mapy jsou výsledkem přizpůsobené filtrace, což je popsáno v 3.1.2. Z binární reprezentace výřezů původních RGB obrázků je získán skeleton použitím řady morfologických operací. V oblasti mezikruží se řešení úlohy komplikuje tím, že pozorované okno může zahrnout několik úseků cév. Druhý problém je bifurkace některých cév v pozorovaném okně.

Cévy menší velikosti byly částečně zničeny použitím morfologické operace eroze. U některých cév se objevuje chyba při vykreslení přímek kolmo k cévě, což je způsobeno chybami, pocházejícími ze směrových map.





Obr. 6.1 a)Příklad vykreslení jasových profilů pro cévu v oblastí mezikruží; b) Průměrný jasový profil

Další fáze metody je extrakce příznaků, které jsou získány z jasových profilů. Z řady jasových profilů jsou spočítány stejné tři příznaky, které byly zapsány do jediné matice (viz kapitola 3.3). Hodnota každého příznaku byla přiřazena k pozici určitého pixelu, pro který byla vypočítána. Všechny hodnoty příznaků jsou sečteny s úvahou váhového vektoru, který byl vypočítán během procesu trénování a učení neuronové sítě:

$$P_{vys} = P_1 * a_1 + P_2 * a_2 + P_3 * a_3 + b \quad (6.1)$$

Výsledkem jsou obrázky s barevnými oblastmi, které odpovídají hodnotám vypočítaných příznaků.







c)

d)


Obr 6.2 a) Oblast zkoumání; b) Příznak 1 (maximalní jas); c) Příznak 2 (šířka jasového profilu v 50% jasů); d) Příznak 3 (plocha pod grafem jasového profilu);




a)



b)



c)



d)

Obr.6.3 Výsledky klasifikace retinálních snímků cév databáze UBMI, FEKT s použitím algoritmu Ho-Kashyap a) snímek 01_h.jpg; b) snímek 02_h.jpg; c) snímek 03_h.jpg; d) snímek 14_h.jpg;

Z obrázků 6.2b), 6.2c) a 6.2d) byly udělány histogramy, ale nepovedlo se klasifikovat cévy mezikruží podle barev extrahovaných parametrů. Vzniklé histogramy jednotlivých příznaků nedávají nastavit definovaný spolehlivý práh, který by odlišoval tepny a žíly. Matice příznaků byla analyzována s použitím neuronových sítí (viz kapitola 4), přičemž sada pro trénování obsahuje matice příznaků 100% vzorků (viz

obr.3.2 a 3.3). Do testovací sady byly zahrnuty úseky jednotlivých cév mezikruží. Žíly byly označeny jako 1, tepny - jako 0. Výsledek klasifikace s použitím algoritmu Ho-Kashyap je na obrázku 6.3. Pro názornost jsou místa vykreslení jasových profilů zobrazeny jako čtverečky a barva odpovídá výsledku klasifikace. Klasifikátor je funkční a odlišuje velké cévy, které jsou v oblasti v okolí optického disku. Skoro všechny cévy malého průměru rozpoznal jako tepny. Tato nepřesnost vzniká kvůli tomu, že cévy malého průměru nebyly pozorovány v mezích výběru vzorků pro trénovací sadu. V trénovací sadě jsou výřezy příliš velkých tepen a žil v oblasti poblíž optického disku. V budoucnu může být testovací sada rozšířená cévami malých průměrů.

Efektivita použité metody je hodnocena číselně. V tabulce 3 jsou výsledky implementace metody na několik různých snímků z databáze. Bylo vypočítáno procento správně detekovaných a nesprávně detekovaných cév, senzitivita a specifická metoda. Hodnocení metody pro data z databáze ÚBMI bylo uděláno manuálně na základě příznaků odlišení tepen a žil (viz. kapitola 1.3) vzhledem k tomu, že pro tuto databázi nejsou vytvořeny modelové případy klasifikace cévního řečiště , které se jmenují „zlatý standard“ pro hodnocení metody. Detekci také ovlivňuje kvalita použitých retinálních snímků. Efektivita je tím větší, čím lepší je rozlišovací schopnost snímků.

Tab. 6.2: Počet správně a nesprávně detekovaných cév na retinálních snímcích databáze FEKT UBMI, skupina «zdravé oči»

Retinální snímek	Správně klasifikované cévy [%]	Nesprávně klasifikované cévy[%]	Senzitivita klasifikace tepen [%]	Specifická klasifikace tepen[%]
01_h.jpg	57%	43%	63%	45%
02_h.jpg	61%	39%	71%	48%
04_h.jpg	59%	41%	79%	51%
08_h.jpg	63%	37%	73%	55%
11_h.jpg	65%	35%	82%	45%
Střední hodnota	61%	39%	73.5%	48.8%

7. Závěr

Předmětem zájmu této diplomové práce byla analýza barevných snímků sítnice z pohledu klasifikace cévního řečiště a snaha programově realizovat navrženou metodiku. V první části byly prozkoumány vlastnosti sítnice, princip činnosti fundus kamery a byla provedena analýza retinálních snímků z hlediska cévních struktur. V kapitole 2 jsou popsány dostupné metody extrakce parametrů cévního řečiště v oblasti rozpoznávání tepen a žil. Byla navržena metoda klasifikace cévního řečiště, využívající se k detekci požadovaných struktur v obraze pomocí klasifikátoru na základě neuronových sítí. K vývoji metody byla primárně použita obrazová data z digitální fundus kamery CANON CF-60 UVi z databáze dostupné na ÚBMI FEKT v Brně, pocházející z oftalmologické ordinace MUDr. Tomáše Kuběny ve Zlíně. K analýze byly vybrány retinální snímky zdravých očí. Na závěr byla použitá metoda otestována na datech z databáze a výsledky byly kvantitativně zhodnoceny. V etapě předzpracování se provádí extrakce sady příznaků z původních dat. Tyto příznaky jsou rozlišovacím faktorem při následující klasifikaci tepen a žil. Příznaky byly vypočítány na základě analýzy cévních profilů. Analýzou vstupních obrazových dat z pohledu stanovení typických profilů cévních struktur se zabývá kapitola 3. Byly stanoveny tři zásadní příznaky, což jsou hodnota maximálního jasu, šířka jasového profilu v 50% jasu a plocha pod grafem jasového profilu. Tyto příznaky byly získány z výřezů tepen a žil a byly použity pro trénování navrženého klasifikátoru. Popis architektury klasifikátoru na základě perceptronu je uveden kapitola 4. Do trénovací sady je zahrnuto 70% vzorků, vybraných metodou křížkové validace, do testovací sady zbývajících 30% vzorků. Klasifikátor natrénuje model na trénovací sadě a pomocí testovací sady testuje přesnost a výkonnost tohoto modelu. Finální etapa zpracování spočívala v otestování navržené metody na retinálních snímcích v oblasti zájmu. Uvažovaný přístup ke klasifikaci cévního řečiště byl realizován a implementován prostřednictvím programového vybavení počítače. Výsledky klasifikace snímků a jejich diskuse s databází jsou uvedeny v kapitole 6.

V budoucnosti může být navržená metoda modifikována pro zlepšení efektivity. Z vykreslených jasových profilů je možné extrahovat další parametry, charakterizující cévy retiny. To může být výskyt centrálního reflexu nebo porovnání kontrastu pixelů cév a pozadí. Je možné rozšířit oblast analýzy a provádět klasifikace po celém snímku, ale problém je v tom, že cévní parametry se mění s měnící vzdáleností

od optického disku. Trénovací sada vstupující do neuronových sítí může být doplněna vzorky cév sítnice, patřící ke skupině «nemocné oči». Tato skupina zahrnuje retinální snímky očí pacientů, u kterých bylo diagnostikováno glaukomové poškození. Na základě změn průměrů a zakřivení retinálních cév je vhodně snažit se provést klasifikace cév do dvou skupin: zdravé oči a nemocné oči. Takže je možné zkusit různé typy algoritmů lineárních klasifikátorů na základě neuronových sítí.

8. Seznam použité literatury

1. ČIHÁK R., GRIM, M.: *Anatomie*. Grada publishing, Praha 2004 .516 s. ISBN: 80-7169-970-5.
2. VACEK Z. : *Embryologie* . Grada publishing, Praha 2006; 256 s. ISBN: 978-80-247-1267-3.
3. ROZMAN J.: *Elektronické přístroje v lékařství*. ACADEMIA, Praha 2006; ISBN: 80-200-1308.
4. *Specifikace fundus kamery CANON CF-60 UVi*. [cit. 30 dubna 2013] Dostupné na <www: <http://www.lpoproducts.com/Products/LPO13.asp>.>
5. Calvo, David, Ortega, Marcos, Penedo, Manuel G., Rouco M.: *Automatic detection and characterisation of retinal vessel tree bifurcations and crossovers in eye fundus images*", Computer Methods and Programs in Biomedicine, Volume.103, Issue.1, pp.28, 2011, ISSN: 01692607
6. Kondermann C., Kondermann D., Yanb M.: *Blood Vessel Classification into Arteries and Veins in Retinal Images*. International Conference of the IEEE EMBS, pp 196-203, 2003.
7. *Klinika rehabilitační fyziologie*. [cit. 1.května 2013] Dostupné na <<http://www.clivn.ru/diagnost/gd.html>>
8. CHAUDHURI S., CHATTERJEE S., KATZ N., NELSON M., GOLDBAUM M., *Detection of blood vessels in retinal images using two-dimensional matched filters*, IEEE Transactions on Medical Imaging 8 (3) (1989) 263–269.
9. ODSTRČILIK J.: *Analyza barevných snímků sítnice se zaměřením na segmentaci cévního řečiště :diplomové práce*. Brno: Vysoké učení technické v Brně, 82 s. Vedoucí prof. Ing. Jiří Jan, CSc.
10. HOOVER A., KOUZNETSOVA V., GOLDBAUM M.: *Locating blood vessels in retinal images by piece-wise threshold probing of a matched filter response*, IEEE Transactions in Medical Imaging 19 (3) (2000) 203–210.
11. VERMEER K., VOS F., LEMIJ H., VOSSEPOEL A.: *A model based method for retinal blood vessel detection*, Computers in Biology and Medicine 34 (3) (2004) 209–219.

12. RANAGYYAN R., AYRES F., OLOUMI F., ESHGHZADEH-ZANAJANI P.: *Detection of blood vessels in the retina with multiscale gabor filters*, Journal of Electronic Imaging 17 (2) (2008) 023018.
13. NEKOVEI R., SUN Y.: *Back-propagation network and its configuration for blood vessel detection in angiograms*, IEEE Transactions on Neural Networks 6 (1) (1995) 64–72.
14. GAO X., BHARATH A., STANTON A., HUGHES A., CHAPMAN N., THOM S.: *A Method of Vessel Tracking for Vessel Diameter Measurement on Retinal Images*. Medical Image Analysis vol. 11: 47–61, 2007.
15. CAN A., SHEN H., TURNER J., TANENBAUM H., ROYSAM B.: *Rapid automated tracing and feature extraction from retinal fundus images using direct exploratory algorithms*, IEEE Transactions on Information Technology in Biomedicine 3 (2) (1999) 125–138.
16. TSAI C., STEWART C., TANENBAUM H., ROYSAM B.: *Model-based method for improving the accuracy and repeatability of estimating vascular bifurcations and crossovers from retinal fundus images*, IEEE Transactions on Information Technology in Biomedicine 8(2)(2004) 122–130.
17. GRISAN E., PESCE A., GIANI A., FORACCHIA M., RUGGERI A.: *A new tracking system for the robust extraction of retinal vessel structure*, Proc. of the International Conference of the IEEE Engineering in Medicine and Biology Society (IEMBS), vol. 3: 1620–1623, 2004.
18. BEVILAQUA V., CAMBO S., CARIELLO L., MASTRONARDI G., A.: *Combined method to detect retinal fundus features*. IEEE European Conference on Emergent Aspects in Clinical Data Analysis, pp.167-175, 2005.
19. BHUIYAN A., NATH B., CHUA J., RAMAMOCHANARAO K.: *Automatic detection of vascular bifurcations and crossovers from color retinal fundus images*. IEEE International Conference on Signal-Image Technologies and Internet-Based Systems, pp. 711–718, 2007
20. *Boxplots*. [cit. 29. dubna 2013] Dostupné z : <http://www.statmethods.net/graphs/boxplot.html>

21. A. S. KRYLOV, A. V. NASONOV, A. S. SEMASHKO, A. A. CERNOMOREC, V. V. SERGEEV, V. S. AKOPJAN, A. S. RODIN, N. S. SEMENOVA.:
«Počítačová analýza snímků očního pozadí» //: VIII Rusko-Bavorská konference biomedicínského inženýrství. Petřeburg, 2012, c. 129–133. PDF.=21
22. CHANWIMALUANG T., FAN G.: *An efficient blood vessel detection algorithm for retinal images using local entropy thresholding*. Proceedings of the 2003 International Symposium on Circuits and Systems 2003; 3 (5): 21-24.
23. LI H., HSU W., LEE M. L.: *A piecewise gaussian model for profiling and differentiating retinal vessels* [HTML dokument]. School of Computing, National University of Singapore, Singapore 117543. [cit. 30. dubna 2013]. Dostupné z: <<http://citeseer.ist.psu.edu/li03piecewise.html>>
24. JAN J. : *Medical image processing, reconstruction and restoration Concepts and methods*. CRC Tylor and Francis, 2006; ISBN 0-8247-5849-8
25. FRIGGE, MICHAEL, HOAGLIN, DAVID C.: *Some Implementations of the Boxplot*. The American Statistician 1989; 43 (1): 50–54.
26. ROZMAN J., ZONA M., ŽÁK J., SOUČEK R.: *Kokplexní funkční diagnostika cév dolních končetin*. Výsledky řešení grantového projektu GAČR č. 102/95/0758. FEI VUT v Brně , Brno 1988.
27. Doc. Ing KOZUMPLÍK J., CSc. Prof PROVAZNÍK I. : *Umělá inteligence v medicíně*. Skripta, FEKT VUT v Brně, ÚBEMI. 2007.
28. MAŘÍK V.: *Umělá inteligence*. první. vyd: Academia, Praha 1993. 264 s. ISBN 80-200-0496-3
29. HAGAN M.: *Neural network design*. první. vyd. PWS, USA 1996. 734 s. ISBN 7-111-10841-8.
30. *Model umělého neuronu*. [cit. 3. Května 2013] Dostupné na <http://www.google.cz/search?q=model+umeleho+neuronu&source=lnms&tbm=isch&sa=X&ei=UqCMUZWRN5HDswbNn4FA&ved=0CAcQ_AUoAQ&biw=1280&bih=638#imgrc=JF1IrjMytoToRM%3A%3BKcWFRVnNltloPM%3Bhttp%252F%252Fupload.wikimedia.org%252Fwikipedia%252Fcommons%252Fthumb%252F3%252F35%252FNeuronModel.jpg%252F220pxNeuronModel.jpg%3Bhttp%253A%252F%252Fcs.wikipedia.org%252Fwiki%252FNeuronov%2525C3%2525A1_s%2525C3%2525AD%2525C5%2525A5%3B220%3B104>

31. KOLÁŘ R.: *Diagnostika bio- a ekosystémů, ZS pro diagnostiku oka -přednáška*. Skripta, FEKT VUT v Brně, ÚBMI. 2008.
32. *Fundus kamera CANON CF-60 UVi*. [cit. 5. května 2013] Dostupné na <<http://www.medwow.com>>
33. HLAVÁČ V., ŠONKA M.: *Základy počítačového vidění*. Grada Publishing, Praha 1992. 272 s. ISBN 80-85424-67-3.
34. Neuronové sítě [cit. 30. Dubna 2013] Dostupné na <<http://avari.cz/uir/index.php?pg=perceptron>>
35. DOUGLAS J.: *Diagnostika a léčba očních chorob v praxi*. Triton, 3. vyd., Praha 2004. 620 s. ISBN-10: 80-7254-536-1
36. LEE S.Y., KIM K.K., SEO J.M., KIM D.M. CHUNG H., PARK K.S., KIM H.C.: *Automated quantification of retinal nerve fiber layer atrophy in fundusphotograph*, 26th Annual International Conference of the IEEE IEMBS, vol.1:1241 - 1243, 2004.
37. ROTHUS K., JIANG, XIAOYI: *Classification of arteries and veins in retinal images using vessel profile features* 2011 INTERNATIONAL SYMPOSIUM ON COMPUTATIONAL MODELS FOR LIFE SCIENCES (CMLS-11). AIP Conference Proceedings, Volume 1371, pp. 9-18 (2011).

Použité zkratky a symboly

MATLAB Matrix laboratory

UBMI Ústav biomedicínského inženýrství

VUT Vysoké učení technické

FEKT Fakulta elektrotechniky a komunikačních technologií

MUDr. Medicinae universae doctor

Lat Latinský jazyk

Obr Obrazek

FOV Field of View

FA Fluoresceinová angiografie

ICG Joint Photographic Experts Group

CCD Charged Couple Device

CMOS Complementary Metal Oxide Semiconductor

RGB Red Green Blue

JPEG Joint Photographic Experts Group