

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

AUTOMATICKÁ DETEKCE VÝPADKU VE VRSTVĚ NERVOVÝCH VLÁKEN

AUTOMATIC SENSE LOSS ON LAYER NERVE FIBRE

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE Bc. Martin Václavek
AUTHOR

VEDÚCÍ PRÁCE doc. Ing. Radim KOLÁŘ, Ph.D.
SUPERVISOR

BRNO 2010

**ZDE VLOŽIŤ
ORIGINALNE
ZADANIE**

LICENČNÍ SMLOUVA POSKYTOVANÁ K VÝKONU PRÁVA UŽÍT ŠKOLNÍ DÍLO

uzavřená mezi smluvními stranami:

1. Pan/paní

Jméno a příjmení: Martin Václavek
Bytem: Dibrovova 244, Stará Turá, 91601
Narozen/a (datum a místo): 27.7.1984 v Trenčíně
(dále jen „autor“)

a

2. Vysoké učení technické v Brně

Fakulta elektrotechniky a komunikačních technologií
se sídlem Údolní 53, Brno, 602 00
jejímž jménem jedná na základě písemného pověření děkanem fakulty:
prof. Ing. Jiří Jan, CSc, předseda rady oboru Biomedicínské a ekologické inženýrství
(dále jen „nabyvatel“)

Čl. 1 Specifikace školního díla

1. Předmětem této smlouvy je vysokoškolská kvalifikační práce (VŠKP):

- disertační práce
 - diplomová práce
 - bakalářská práce
 - jiná práce, jejíž druh je specifikován jako
- (dále jen VŠKP nebo dílo)

Název VŠKP: Automatická detekce výpadku ve vrstvě nervových vláken
Vedoucí/ školitel VŠKP: doc. Ing. Radim KOLÁŘ, Ph.D.
Ústav: Ústav biomedicínského inženýrství
Datum obhajoby VŠKP: 7. nebo 8. června 2010

VŠKP odevzdal autor nabyvateli :

- v tištěné formě – počet exemplářů: 2
- v elektronické formě – počet exemplářů: 2

2. Autor prohlašuje, že vytvořil samostatnou vlastní tvůrčí činností dílo shora popsané a specifikované. Autor dále prohlašuje, že při zpracovávání díla se sám nedostal do rozporu s autorským zákonem a předpisy souvisejícími a že je dílo dílem původním.
3. Dílo je chráněno jako dílo dle autorského zákona v platném znění.
4. Autor potvrzuje, že listinná a elektronická verze díla je identická.

Článek 2

Udělení licenčního oprávnění

1. Autor touto smlouvou poskytuje nabyvateli oprávnění (licenci) k výkonu práva uvedené dílo nevýdělečně užit, archivovat a zpřístupnit ke studijním, výukovým a výzkumným účelům včetně pořizování výpisů, opisů a rozmnoženin.
2. Licence je poskytována celosvětově, pro celou dobu trvání autorských a majetkových práv k dílu.
3. Autor souhlasí se zveřejněním díla v databázi přístupné v mezinárodní síti

- ihned po uzavření této smlouvy
- 1 rok po uzavření této smlouvy
- 3 roky po uzavření této smlouvy
- 5 let po uzavření této smlouvy
- 10 let po uzavření této smlouvy (z důvodu utajení v něm obsažených informací)

4. Nevýdělečné zveřejňování díla nabyvatelem v souladu s ustanovením § 47b zákona č. 111/ 1998 Sb., v platném znění, nevyžaduje licenci a nabyvatel je k němu povinen a oprávněn ze zákona.

Článek 3

Závěrečná ustanovení

1. Smlouva je sepsána ve třech vyhotoveních s platností originálu, přičemž po jednom vyhotovení obdrží autor a nabyvatel, další vyhotovení je vloženo do VŠKP.
2. Vztahy mezi smluvními stranami vzniklé a neupravené touto smlouvou se řídí autorským zákonem, občanským zákoníkem, vysokoškolským zákonem, zákonem o archivnictví, v platném znění a popř. dalšími právními předpisy.
3. Licenční smlouva byla uzavřena na základě svobodné a pravé vůle smluvních stran, s plným porozuměním jejímu textu i důsledkům, nikoliv v tísní a za nápadně nevýhodných podmínek.
4. Licenční smlouva nabývá platnosti a účinnosti dnem jejího podpisu oběma smluvními stranami.

V Brně dne: 19. května 2010

.....
Nabyvatel

.....
Autor

Abstrakt

Práca je zameraná na detekciu výpadkov vo vrstve nervových vlákien na farebných snímkoch očnej sietnice vyhotovených fundus kamerou. Popisuje jednotlivé objekty sietnice, optický disk, žltú škvrnu, a cievne riečište. Detekuje optický disk a jeho okolie, ktoré je podstatné pre detekciu výpadkov nervových vlákien. Pre spracovanie obrazu a detekciu objektov využíva rôzne metódy úpravy obrazu (segmentáciu, prahovanie, zvýšenie kontrastu, houghovu transformáciu). Samotná detekcia výpadkov vo vrstve nervových vlákien je založená na porovnávaní štatistických parametrov (priemer, smerodatná odchylka, koeficient šikmosti a spičatosti histogramu, entropiu) vo vybraných oblastiach bez poškodenia a s poškodením vrstvy nervových vlákien. Cievne riečište znehodnocuje výsledky, preto sú vzorky vyberané ručne. Výsledky práce značne znehodnocuje rozsiahle cievne riečište v detekovanom okolí optického disku.

Abstract

This work is focused on detection of loss in nerve fibre layer on colour pictures of retina, which are made by fundus camera. It describes every simple object of retina, optic nerve head, macula lutea and vascular bed. It detects optic nerve head and its near area, which is general for detection of breakdowns. It uses several methods of picture adjusting for picture elaboration and object detection (segmentation, thresholding, enhancement, hough transformation). The detection of loss in nerve fibre layer is based on comparing of statistical parameters (average, standard deviation, skewness coefficient and kurtosis coefficient histogram, entropy) in chosen areas with and without destruction of nerve layers. Vascular bed has bad effect on results, because of this we use hand choosing of essay.

Kľúčové slová:

Vrstva nervových vlákien, optický disk, detekcia, sietnica, houghova transformácia, segmentácia, prahovanie, filtrácia, lokálne zvýšenie kontrastu, spracovanie obrazu.

Keywords:

Nerve fibre layer, optic nerve head, detection, retina, hough transformation, segmentation, thresholding, filters, enhancement, image processing

Bibliografická citace mé práce:

VÁCLAVEK, M. *Automatická detekce výpadku ve vrstvě nervových vláken*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2010. XY s. Vedoucí diplomové práce doc. Ing. Radim Kolář, Ph.D.

Prehlásenie

Prehlasujem, že svoju diplomovú prácu na tému Automatická detekcia výpadkov vo vrstve nervových vlákien som vypracoval samostatne pod vedením vedouceho diplomovej práce a s použitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej diplomovej práce taktiež prehlasujem, že vytvorením tejto diplomovej práce som neporušil autorské práva tretích osôb, rozhodne som nezasiahol nedovoleným spôsobom do cudzích autorských práv a som si plne vedomý následkov porušenia ustanovenia § 11 autorského zákona č. 121/2000 Sb., vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia § 152 trestného zákona č. 140/1961 Sb.

V Brne dňa 5. mája 2009 podpis autora

PodĎakovanie

Ďakujem vedúcemu diplomovej práce doc. Ing. Radimu Kolářovi, Ph.D. za nezbytnú, účinnú pedagogickú a odbornú pomoc a taktiež za ďalšie hodnotné rady pri zpracovávaní mojej diplomovej práce.

V Brne dňa 5. mája 2009 podpis autora

OBSAH

1	ÚVOD	11
2	OČNÉ POZADIE (SIETNICA)	12
2.1	ŽLTÁ ŠKVRNA (ZS).....	12
2.2	SLEPÁ ŠKVRNA (OD).....	12
2.3	OSTATNÉ OBJEKTY.....	12
2.4	VÝŠETRENIE FUNDUS KAMEROU.....	13
2.4.1	<i>Konštrukcia fundus kamery</i>	13
3	SPRACOVANIE OBRAZU	14
3.1	DIGITÁLNY OBRAZ.....	14
3.1.1	<i>Základne druhy obrazu</i>	14
3.2	OBEČNÝ POPIS OBRAZU SIETNICE.....	14
3.3	PREDSPRACOVANIE OBRAZU.....	15
3.3.1	<i>Filtrácia</i>	16
3.3.2	<i>Segmentácia</i>	17
3.3.3	<i>Prahovanie</i>	17
3.3.4	<i>Lokálne zvýšenie kontrastu (LZK)</i>	18
3.4	ZÁMER SPRACOVANIA PRÁCE.....	18
4	DETEKCIA OPTICKÉHO DISKU	20
4.1	LOKALIZÁCIA OD KONVOLÚCIOU.....	20
4.2	PROBLÉMY LOKALIZÁCIE OD.....	21
5	HOUGHOVA TRANSFORMÁCIA (HT)	23
5.1	HOUGHOVA TRANSFORMÁCIA PRE KRUŽNICU.....	23
5.2	CANNYHO DETEKTOR HRÁN PRE HOUGHOVU TRANSFORMÁCIU.....	24
5.2.1	<i>Problémy u Cannyho detektoru hrán</i>	25
5.2.2	<i>Nastavenie Cannyho detektoru hrán</i>	25
5.3	VÝSLEDKY HOUGHOVEJ TRANSFORMÁCIE (HT).....	26
6	DETEKCIA CIEVNEHO RIEČIŠŤA	28
6.1	HRANOVÉ DETEKTORY.....	28
6.1.1	<i>Detekcia pomocou prvej derivácie</i>	28
6.2	VÝSLEDKY DETEKcie CIEVNEHO RIEČIŠŤA.....	29
6.2.1	<i>Prevod súradnicového systému</i>	29
6.2.2	<i>Lokálne zvýraznenie kontrastu</i>	32
6.2.3	<i>Použitie hranové detektory</i>	33
7	DETEKCIA VÝPADKOV VO VRSTVE NERVOVÝCH VLÁKIEN (VNV)	37
7.1	METODIKA.....	37
7.1.1	<i>Koeficient šikmosti a špičatosti histogramu</i>	40
7.1.2	<i>Entropia</i>	42
7.1.3	<i>Variačný koeficient</i>	42
7.1.4	<i>Smerodatná odchylka</i>	42
7.2	VÝSLEDKY DETEKcie VÝPADKOV VNV.....	42
7.2.1	<i>Štatistické parametre</i>	44
8	ZÁVER	49
	ZOZNAM POUŽITEJ LITERATÚRY	51
	UŽÍVATEĽSKÉ ROZHRAŇIE	52
	ZOZNAM SKRATIEK	56

Zoznam obrázkov

Obrázok. č.1:	13
Principiálne schéma fundus kamery	13
Obrázok č.2: a) RGB – snímok sietnice b) šedotónový – snímok sietnice	15
Obrázok č.3: Zložka R(červená), zložka G(zelená), zložka B(modrá), zložka G+B(modrá+zelená)	16
Obrázok č.5: Detekovaný OD	20
Obrázok č.6: Snímok (G+B zložka) sietnice poškodenej diabetesom	21
Obrázok č.7: Výrez snímku (G+B zložka) sietnice poškodenej diabetesom	21
Obrázok č.8: Výber median hodnoty z bodov maxim výstupu konvolúcie obrazu s maskou	22
Obrázok č.9: Detekcia OD s veľkosťou masky (maska 15x15 vľavo, maska 5x5 vpravo)	22
Obrázok č.10: Princíp houghovej transformácie	24
Obrázok č.11: Detekcia hrán cannyho detektorom.....	25
Obrázok č.12: Segmentácia OD houghovou transformáciou (správna).....	26
Obrázok č.13: Segmentácia OD houghovou transformáciou (nesprávna).....	27
Obrázok č.14: Princíp prevodu z polárnych do kartéznych súradníc.....	30
Obrázok č.15: Obrazy detekcie v polárnych súradniciach.....	30
Obrázok č.16: Obraz pre detekciu prevedený do kartéznych súradníc.....	31
Obrázok č.17: Obraz pre detekciu prevedený do kartéznych súradníc.....	31
Obrázok č.18: LZK pre neošetrené okrajové riadky	32
Obrázok č.19: LZK pre malú masku	32
Obrázok č.20: LZK pre ideálnu masku	33
Obrázok č.21: LZK pre veľkú masku	33
Obrázok č.22: Binárny obraz operátoru sobel 3x3 pre prahovanie medián	34
Obrázok č.23: Binárny obraz operátoru prewitt 5x5 pre prahovanie medián	34
Obrázok č.24: Binárny obraz operátoru kirsch 3x3 pre prahovanie medián	35
Obrázok č.25: Binárny obraz sobel vložený do originálu	35
Obrázok č.26: Binárny obraz prewitt vložený do originálu	36
Obrázok č.27: Binárny obraz kirsch vložený do originálu	36
Obrázok č.28: Znázornenie oblasti výpadku VNV v originálnom obraze.....	37
Obrázok č.29: Oblasť výpadku v obraze s kartézskymi súradnicami	38
Obrázok č.30: Výber vzorkov v oblasti výpadku VNV (červené), v oblasti bez výpadku (zelené)	39
Obrázok č.31: Skupina s oblasťou výpadku VNV (B)	39
Obrázok č.32: Skupina bez výpadku VNV (B)	40
Obrázok č.33: Šikmosť histogramu.....	41
Obrázok č.34: Strmosť histogramu.....	41
Obrázok č.35: graf štatistických parametrov image_2891.jpg (zelená-Skupina A, červená-skupina B) ...	44
Obrázok č.36: graf štatistických parametrov kos1.jpg (zelená-Skupina A, červená-skupina B).....	45
Obrázok č.37: graf štatistických parametrov květoňová3.jpg (zelená-Skupina A, červená-skupina B)	47
Obrázok č.38: graf štatistických parametrov herman4.jpg (zelená-Skupina A, červená-skupina B)	48
Obrázok č.39: graf štatistických parametrov houšťová3.jpg (zelená-Skupina A, červená-skupina B).....	48
Obrázok č.41: Rozhranie funkcie <i>houghova_transformac</i>	52
Obrázok č.42: Rozhranie funkcie <i>pol_cart</i>	53
Obrázok č.43: Rozhranie funkcie <i>pol_cart</i> (výsledky po spustení výpočtu).....	54
Obrázok č.44: Rozhranie funkcie <i>Detekce_VNV</i>	55
Obrázok č.45: Rozhranie funkcie <i>Detekce_VNV</i>	55

Zoznam tabuliek

Tabuľka č.1: štatistické paramete image_2891.jpg.....	44
Tabuľka č.2: štatistické paramete kos1.jpg	45
Tabuľka č.3: štatistické paramete květoňová3.jpg	46
Tabuľka č.4: štatistické paramete herman4.jpg	47
Tabuľka č.5: štatistické paramete houšťová3.jpg.....	48

1 Úvod

Pre detekovanie výpadku vo vrstve nervových vlákien (VNV) u farebných oftalmologických obrazov je nutnosťou nadobudnúť základné poznatky o anatómii ľudského oka. Pre túto prácu sú hlavné poznatky o očnej sietnici, ktorá pozostáva z hlavných častí a to slepej škvry (optický disk OD), žltej škvry (ZS) a očných ciev a nervov. Segmentácia optického disku a žltej škvry zohráva dôležitú úlohu pri diagnostike oftalmologických obrazov.

Zmienka o prvej metóde detekcie vrstvy nervových vlákien (VNV) vo farebných snímkoch sietnice z fundus kamery je už z osemdesiatych rokov 20. storočia. Metóda je často nazývaná (počítačová) densitometria vrstvy nervových vlákien. V jednej z prvých štúdií autori Ludstrom a Eklundh [1] popisujú metódu pre hodnotenie VNV na digitalizovaných snímkoch. Hodnotenie metódy je založené na jasových profiloch pozdĺž sústredných kružníc okolo optického disku. Zaujímavá je tiež zmienka z roku 1980, Frisénovej štúdie [1], v ktorej doporučuje pre optimálne snímanie VNV používať bežný fotografický film s využitím modrozelených filtrov. Tento poznatok sa využíva neodmysliteľne až do dnes.

S rozvojom počítačov koncom devedesiatych rokov 20. storočia sa začínajú objavovať práce, využívajúce zložitejšie parametre založené na textúrnej analýze VNV. Quigley [1] dokazuje na rade prípadov, že je možné detekovať úbytok hrúbky VNV (tlstoty VNV) a to do určitej miery aj kvantitatívne. Jeho teória uvádza, že hrúbka VNV musí byť minimálne v rozsahu 25-50 μm , aby bola v snímku vizuálne rozpoznateľná. Minimálny pokles hrúbky VNV, ktorý je detekovateľný, sa pohybuje okolo 50 μm so šírkou výpadku 250 μm v blízkom okolí optického disku.

S rozvojom nových metod, ako sú laserová skenovacia polarimetria (prístroje typu GDx) a optická koherentná tomografia (prístroje typu OCT), koncom minulého storočia došlo k poklesu záujmu o vyšetrenie VNV pomocou digitálnej fundus kamery. Behom posledných rokov sa ale opäť záujem o vyšetrenie VNV pomocou digitálnej fundus kamery zvýšil. Je to dané hlavne dostupnosťou fundus kamery, ktorá je základnou súčasťou oftalmologických pracovísk. Taktiež dnešne bežnou možnosťou fotografovať digitálne a snímok ďalej upravovať počítačovými programami tak, že VNV a jej zmeny sú lepšie viditeľné. Dôkazom je niekoľko medzinárodne publikovaných prác [1].

Táto práca je zameraná na detekciu OD, a na získanie štatistických parametrov potrebných pre detekciu výpadkov vo VNV. Najčastejšie výpadky vo VNV sa prejavujú práve v blízkosti OD preto je určenie jeho polohy pre nás dôležitým zistením. Spracovávané obrázky sú farebné snímky (RGB snímky) zachytené pomocou fundus kamery Canon CF-60UV s digitálnou zrkadlovkou Canon EOS 20D.

Testovanie bolo vykonávané na 22 obrázkoch z databázy ÚBMI (viz. *CD priložené k práci*), kde 2 obrázky sú snímané cez modrozelený filter a 20 obrázkov je snímaných bez farebných filtrov. Po upravení používame iba ich GB zložku (zelenú a modrú), ktorá nám dáva najjasnejšiu informáciu pre určenie polohy OD. Tento poznatok je už dlho známy a aj využívaný.

2 Očné pozadie (sietnica)

Očné pozadie (sietnica - retina) je vlastným orgánom zraku. Je to tenká, priehľadná membrána, ktorá nalieha na cievnatku a vystiela z vnútornej strany očnú stenu. Má oranžovú až červenú farbu, ktorá vzniká presvitáním ciev cievnatky. Má väčšiu zadnú časť a menšiu prednú časť. Predná časť nemá význam pre zrakové vnemy a tvorí ju len pigmentová vrstva.

Sietnica plní funkciu porovnateľnú ako film vo fotoaparáte. Princíp spočíva v tom, že optika oka vytvorí predstavu o vizuálnom svete na sietnicu, ktorá sa začne z ľahka sťahovať. Následkom týchto sťahov sietnica zaháji kaskádu chemických a elektrických udalostí, ktoré nakoniec odistia nervové impulzy. Tie sú potom posielané k rôznym vizuálnym centráram mozgu cez vlákna zrakového nervu. Preto je sietnica považovaná za časť centrálnej nervovej sústavy.

Má plochu niekoľko cm^2 a obsahuje zmyslové bunky, ktorými sú tyčinky a čapíky. Čapíky nám umožňujú vidieť farebne za denného svetla a tyčinky čiernobielo za šera. Najväčšie zoskupenie čapíkov je na žltej škvrne (ZS), tá je najdôležitejším centrom nášho ostrého videnia detailov. Periferná časť sietnice slúži k perifernému videniu. Zásobovanie sietnice kyslíkom nám zaisťujú sietnicové tepny a žily. Ich poruchy (uzavretie alebo krvácanie) vedú k závažným poruchám zraku. Viditeľná časť spektra je v rozmedzí 400-700 nm. [2]

2.1 Žltá škvrna (ZS)

Žltá škvrna (fovea) je miesto na očnej sietnici nachádzajúca sa v ose oka, približne priemeru 0,2-0,5mm, kde je najväčšia koncentrácia zmyslových buniek (*hlavne čapíkov, tyčinky v úplnom strede ZS niesú žiadne*). Na 1mm^2 žltej škvrny pripadá asi 150 000 čapíkov. Obsahuje karotenoidy lutein a zeaxantin, ktoré slúžia ako antioxidanty. ZS slúži k ostrému a farebnému dennému videniu a vysoké rozlíšenie podporuje aj fakt, že každý čapík v ZS má svoj vlastný optický nerv. Rozlišujeme tri druhy čapíkov, ktoré sú citlivé na vlnové dĺžky odpovedajúce farbám modrá, zelená a červená. Rôzna intenzita podráždenia všetkých čapíkov vyvolá na princípe miešania farieb celú farebnú škálu.

ZS zažíva v skutočnosti nie je žltá, ale o trochu červenšia ako jej okolie. Názov jej bol priradený na základe toho, že sa žltou javí u mŕtvol.

2.2 Slepá škvrna (OD)

Slepá škvrna (optický disk OD) je miesto, kde zrakový nerv opúšťa očnú sietnicu. Toto miesto sietnice neobsahuje žiadne zmyslové bunky (*tyčinky a čapíky*), preto je aj ten názov "slepá škvrna". Zrakový nerv prenáša všetky informácie videnia (*vnímane okom*) až do zrakového centra mozgu. Na očnom pozadí sa OD javí ako nažltnutá oblasť, ktorá je približne veľká jednu sedminu z celkového obrazu sietnice. [2]

2.3 Ostatné objekty

Medzi ostatné objekty očného pozadia (sietnice) patria hlavne sietnicové cievy (tepny a žily), ale takisto aj nervové vlákna.

Sietnicové cievy (tepny a žily) sú na snímkoch dobre viditeľné. Zásobovacie cievy vychádzajú z OD, kde majú najväčšiu šírku a postupne sa ich profil zmenšuje smerom do

priestoru. Niektoré cievy, hlavne širšie sú charakteristické centrálnym reflexom, ktorý sa prejavuje tenkým svetlým prúžkom uprostred cievy. Rozlišovanie tepien a žíl v snímkoch je založené hlavne na poznatku, že tepny sú svetlejšie a tenšie, zatiaľ čo žily sú tmavšie a hrubšie.

Nervové vlákna nie sú na snímkoch tak ľahko badateľné. Na detekovanie jednotlivých vrstiev nervových vlákien (VNV) sa využívajú rôzne metódy založené hlavne na jasových rozlíšeníach, ale zatiaľ neboli hlbšie preskúmané a overené v praxi.

Ďalej v tejto práci sa budeme zaoberať skúmaním týchto metód a hľadaním vhodného riešenia pre určenie výpadku vo VNV.

2.4 Výšetrenie fundus kamerou

Fundus kamera je zariadenie, nahrádzajúce oftalmoskop, ktoré slúži k vyšetreniu očného pozadia (sietnice). V dnešnej dobe je bežnou súčasťou oftalmologických zariadení, kde má hlavné využitie v podpore diagnostiky napríklad glaukomu (zelený zákal), diabetosu, degenerácie sítnice a ďalších chorôb týkajúcich sa očného pozadia.

V jednoduchosti povedané, jedná sa o retinálnu kameru, ktorej systém umožňuje korigovať aj vysoké hodnoty ametropie (zlá refrakčná schopnosť oka).


Prístroj je vybavený zdrojom bieleho svetla (*osviecuje sietnicu*) a CCD prvkom (*zaznamenáva obraz sietnice*). Medzi ďalšie vybavenia fundus kamery väčšinou patria, systém pre automatické najdenie stredu sietnice, a taktiež systém automatického ošetrenia. Systém automatického ošetrenia sa vykonáva pomocou frekvenčnej analýzy snímaného obrazu hodnotením obsahu vysokých frekvencií. Ďalej obsahujú systém automatického riadenia intenzity osvetlenia sietnice, kedy sa vyhodnocujú predchádzajúce snímané obrazy a intenzita osvetlenia sa upravuje na základe priemeru jasu v týchto obrazoch.

Prístroj sa dnes vyrába zväčša v digitálnej forme, v ktorej plne nahrádza oftalmoskop. Konštrukcia a popis jednotlivých častí fundus kamery sa nachádza v nasledujúcej podkapitole s obrázkom (viz. *Obrázok č.1*). [2, 3]

2.4.1 Konštrukcia fundus kamery

Časti fundus kamery:

1. Zobrazovacia jednotka
2. Pozičná jednotka
3. Pozičná jednotka
4. Pozičná jednotka
5. Operačný panel pre lekára
6. Objektív
7. PC (počítač)



Obrázok. č.1:
Principiálne schéma fundus kamery

3 Spracovanie obrazu

3.1 Digitálny obraz

Pre vhodné spracovanie obrazu v počítačoch je nutný prevod spojitého analógového signálu na signál digitálny (tzv. digitalizácia).

Digitálny obraz je definovaný, ako ekvivalent spojitej obrazovej funkcie $f(x, y)$, kde x a y sú súradnice jednotlivých bodov v priestore. Je získaný pomocou vzorkovania obrazu do matice $M \times N$ bodov a kvantovaním do K úrovní.

Amplítúda bodov dvojrozsmernej funkcie je nezyvana jas. Najmenším elementom v takomto obraze je pixel. Digitálny obraz je teda diskrétno pole pixelov, kde intenzita každého pixelu je reprezentovaná číslom [2].

3.1.1 Základne druhy obrazu

Binárny obraz:

Binárny obraz (viz. *Obrázok č.11*) je taký, ktorý je tvorený iba kombináciou 0 a 1. Výsledkom je teda vytvorené binárne pole. Využitie má predovšetkým pri segmentácii a prahovaní.

Šedotónový obraz:

Šedotónový obraz (viz. *Obrázok č.2b*) je určený pre aplikácie, kde k spracovaniu postačujú hodnoty intenzít v stupňoch šedi. Je definovaný v rozmedzí biela-stupne šedi-čierna. Najčastejšie sa využíva 256 odtieňov (8 bitov hĺbky), kde 0 reprezentuje čiernu a 256 reprezentuje bielu.

RGB obraz:


RGB obraz (viz. *Obrázok č.2a*) vychádza z princípu, že každý bod (pixel) obrazu je tvorený za pomoci troch farebných zložiek. A to červenej, zelenej a modrej. Ich zlúčením vzniká celá paleta farieb.

Hodnota reprezentujúca čiernu v takomto obraze je 0,0,0. So zvyšujúcou hodnotou farby sa hodnoty farby pridávajú až po maximálnu hodnotu 1,1,1, ktorá reprezentuje bielu farbu. Ak sú jednotlivé hodnoty zložiek rovnaké, jedná sa o odtieň šedi. Takýto model sa nazýva aditívny. Taktiež jako u obrazu šedotónového, aj tu sa využíva najmä rozsah 0-255, takže môžeme pracovať aj s hĺbkou farby.

3.2 Obecný popis obrazu sietnice

Na *obrázku č.1* je zachytené očné pozadie (sietnica), zaznamenané pomocou digitálnej fundus kamery CANON CF-60 UVi so zabudovaným digitálnym fotoaparátom CANON EOS-20D. Približne v prostriedku obrazu sa nachádza ZS, ktorá sa prejavuje ako tmavý okrúhly útvar, jak v RGB snímku, tak aj v šedotónovom snímku. Ďalej je vidieť podstatne väčší okrúhly nažltnutý (v šedotónovom snímku biely) útvar v ľavej polovine RGB snímku, ktorý je OD. Hodnotenie tvaru OD a ciev je možné využívať pre diagnostiku centrálného nervového systému.

Na *obrázku č.1b* môžeme zreteľnejšie spozorovať nervové vlákna, ktoré sú charakteristické svetlým žihaním najlepšie viditeľným v okolí OD, kde sa zbiehajú a opúšťajú sietnicu. Najväčšia koncentrácia nervových vlákien je v oblasti ZS, kde ale na snímkoch nie sú skoro vôbec viditeľné. Vedecké práce zaoberajúce sa touto problematikou (*analýza VNV*) sú napríklad [4] a [5].



a)


b)

Obrázok č.2: a) RGB – snímok sietnice b) šedotónový – snímok sietnice

3.3 *Predspracovanie obrazu*

Úlohou predspracovania obrazu po jeho načítaní je, prichystať si daný obraz do potrebnej pobodby umožňujúcej jeho ďalšie spracovávanie. Obraz môže byť skreslený či už spôsobom snímania, alebo nevhodnými podmienkami jeho reprezentácie. V prípade, že je známy charakter skreslenia, je možné túto chybu opraviť pomocou korekcií, ktoré sú jednou z metód predspracovania obrazu. Metód predspracovania existuje veľké množstvo (napr. *Filtrácia, ostrenie obrazu, jasová transformácia...*). Slúžia hlavne k uľahčeniu analýzy obrazu, rozpoznávaniu objektov, zvýrazňovaniu detailov a rysov obrazu. Všetko za účelom z kvalitného obrazu pre pozorovateľa (človeka) [2, 3].

Predspracovanie v našom prípade spočívalo v tom, že sme si načítali RGB obraz a následne sme si ho upravili rozdelením na tri základné farebné zložky: modrá (B), červená (R), zelená (G) (viz. *Obrázok č. 3*). Jednotlivé zložky sú kvantované do 256 úrovní. Po tejto úprave je vidieť, že najväčšiu mieru informácie o dôležitých objektoch sietnice nám poskytujú obrázky modrej a predovšetkým zelenej zložky. U červenej zložky je snímok dosť presvetlený a neposkytuje tak dostatok informácií o cievnom riečišti ani o nervových vláknach. Preto bolo k ďalšej práci s obrazom používaný súčet modrej a zelenej zložky (viz. *Obrázok č.3 zložka G+B*).



Obrázok č.3: Zložka R(červená), zložka G(zelená), zložka B(modrá), zložka G+B(modrá+zelená)

3.3.1 Filtrácia

Filtrácia slúži k redukovaniu šumu v signáloch (1D, 2D...). U filtrácie obrazov sa používajú tzv. priestorové filtre. Využívajú sa metódy pre výpočet jasov bodu vo výstupnom obraze iba z lokálneho okolia odpovedajúceho bodu vo vstupnom obraze. Na filtráciu môžeme pohliadať taktiež ako na diskretnú konvolúciu (konvolučné jadro definuje použité lokálne okolie). V množstve prípadov sa využíva pravouhlé okolie a aby použité okolie bolo symetrické voči stredovému elementu, volia sa najčastejšie rozmery okolia z lichých prirodzených čísel. [8]

Lineárna filtrácia (lineárne filtre) je použiteľná pre vyhladzovanie i detekciu hrán. Získaným výsledkom vyhladzovania je potlačenie náhodného šumu, ale tiež vzniká nežiadúci efekt, ktorým je potlačenie ostatných náhlych zmien jasovej funkcie (rozmazanie hrán). Jednoduchým príkladom vyhladzovania je priemerovanie. V princípe to funguje tak, že každému bodu priradíme nový jas, ktorý získavame priemerom pôvodných jasov vo zvolenom okolí. Niekedy sa zvyšuje váha stredného bodu masky (jadra), alebo jeho susedov, aby sa lepšie aproximovali vlastnosti šumu. Jedným z najznámejších lineárnych filtrov je *Gaussov filter*, ktorý má definíciu:

$$f(x, y) = \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (1)$$

σ - smerodatná odchyľka filtru

3.3.2 Segmentácia

Segmentácia je veľmi zložitý proces, ktorej náročnosť súvisí nielen s charakterom a vlastnosťami objektov obrazu. Jej úspešnosť značne ovlivňujú i vstupné data. Úplne znemožniť segmentáciu môže značný podiel šumu, alebo nerovnomerné rozloženie jasu v obraze. Takéto prípady riešime vhodným predspracovaním vstupného obrazu za účelom vylepšenia výsledkov segmentácie (napr. *filtrácia*).

Obecná definícia segmentácie hovorí, že ide o proces delenia obrazu do častí, ktoré korešpondujú s konkrétnymi objektmi v obraze (každému pixelu je priradený index segmentu vyjadrujúci určitý objekt v obraze). Segmentácia je považovaná za jeden z najdôležitejších krokov analýzy obrazu. Informáciu o rozdelení obrazu do jednotlivých segmentov využívajú vyššie algoritmy zpracovávania obrazu (spracovávajú porozumenie obsahu obrazu). Konkrétnou úlohou môže byť detekcia prítomnosti príslušného objektu v obraze. [8]

V dnešnej dobe existuje množstvo segmentačných algoritmov. Táto práca bola zameraná predovšetkým na metódy vychádzajúce s detekcie hrán. Lokálne hrany sú u týchto metód detekované pomocou hranových detektorov na základe rozdielu hodnôt okolných pixelov. Hranový detektor je algoritmus, ktorý produkuje množinu hrán (bodov, pixelov, fragmentov) v obraze. Hrany sú miesta v obraze, kde vzniká určitá nespojitosť (väčšinou v jase, kedy sa hodnota jasu prudko mení). Každá hrana je reprezentovaná veľkosťou a smerom, a preto môžeme hranu chápať ako vlastnosť obrazového bodu, ktorý predstavuje funkciu obrazu v okolí tohoto bodu. V obrazoch môžeme nájsť rôzne typy hrán. Priebehu ideálnej hrany odpovedá skok. Algoritmus detekcie hrán delíme na tri časti [9]:

- Filtrovanie (odstránenie šumu)
- Diferenciácia (zvýraznenie oblastí)
- Detekcia (lokalizácia bodov)

3.3.3 Prahovanie

Prahovanie je metóda využívaná pri predspracovaní obrazu. Poskytuje jednoduchú a vyhovujúcu cestu, ako na základe rozdielnych intenzít farieb oddeliť objekty obrazu od pozadia obrazu. Takisto je použiteľná pre oddelenie pixelov, ktorých odtieň, alebo intenzita leží vo špecifickom intervale hodnôt.

Vstupom pre prahovanie je obvykle obraz v stupňoch šedi. Výstupom je potom v bežných implementáciách binárny obraz. Čierne pixeli odpovedajú pozadiu a biele objektu záujmu. Rozhodnutie sa prevádza na základe jedného parametru, nazývaného prah intenzity. Pixeli sú pri jednom priechode obrazom porovnávané so stanovenou hodnotou prahu. Ak je intenzita farby vyššia než prah, je výsledný pixel biely, v opačnom prípade čierny (poprípade naopak). K najdeniu správnej hodnoty prahu sa najčastejšie využíva histogram. [4]

Lokálne prahovanie je metóda, ktorá hľadá prahovú hodnotu pre každý pixel štatistickým vyšetrením intenzít jasu v lokálnom okolí bodu. Druh štatistiky, ktorá je najvhodnejšia, je do značnej miery závislý na vstupnom obraze. Jednoduché (rýchle) funkcie pre túto operáciu počítajú s hodnotou T . Najčastejšie používané hodnoty pre T sú, stredná hodnota (stredná hodnota z intenzít jasu v lokálnom okolí bodu) a medián (prostredná hodnota z intenzít jasu v okolí bodu). Veľkosť okolia musí byť dostatočne rozľahlá, aby pokryla dostatočne veľa pixelov, ktoré sú súčasťou objektu i pixelov pozadia. V opačnom prípade je zvolená zlá prahová hodnota. Na druhú stranu, ak vybereme príliš veľké okolie

bodú, môže to viesť k porušeniu predpokladu, že osvetlenie v lokálnom okolí bodu sa príliš nemení.

3.3.4 Lokálne zvýšenie kontrastu (LZK)

Cieľom lokálneho zvýšenia kontrastu je zmenšiť jasovú variabilitu obrazu, teda zvýšenie kontrastu jasovej zložky pomocou adaptívnej transformácie.

Pre vysvetlenie si predstavme submaticu $W(i,j)$ s rozmermi $M \times M$ pixelov so stredom v pixelu (i,j) . Následným krokom vypočítame strednú hodnotu $\langle f \rangle_w$ (vzorec 2) a smerodajnú odchylku σ_w (vzorec 3) intenzity v submatici $W(i,j)$. Určíme si f_{max} a f_{min} , ktoré uvažujeme ako maximálne resp. minimálne hodnoty intenzity v submatici [2].

$$\langle f_{w(i,j)} \rangle = \frac{1}{M^2} \sum_{(k,l) \in W(i,j)} f(k,l) \quad (2)$$

$$\sigma_w^2(f) = \frac{1}{M^2} \sum_{(k,l) \in W(i,j)} (f(k,l) - \langle f_w \rangle)^2 \quad (3)$$

Následne si definujeme adaptívny lokálny operátor pre zvýšenie kontrastu (vzorec 4).

$$g(i,j) = 255 \cdot \frac{[\psi_w(f) - \psi_w(f_{min})]}{[\psi_w(f_{max}) - \psi_w(f_{min})]} \quad (4)$$

Kde funkcia sigmoidy je definovaná následným vzťahom (vzorec 5):

$$\psi_w(f) = \left[1 + \exp\left(\frac{\langle f_w \rangle - f}{\sigma_w}\right) \right]^{-1} \quad (5)$$

Po aplikácii lokálneho operátora sa obrázok výrazne zmení. Tmavšie miesta obrazu budú zosvetlené, a tým získavame viac informácií o detailoch obrazu (hlavne detaili cievného riečiska).

Nevýhodou tejto transformácie je zvýšenie šumu v obraze, čo je možné kompenzovať použitím nejakého filtru (najvhodnejší *Gaussov filter*). Ďalšia závislosť kontrastu obrazu je na veľkosti použitej masky (submatice $W_{i,j}$). Ak je maska moc malá (viz. *Obrázok č.4a*), objekty a detaily obrazu nie sú moc výrazné. V prípade, že je maska moc veľká (viz. *Obrázok č.4c*), sú objekty a detaily obrazu síce zreteľne rozostrené, ale prejavuje sa v obraze skreslenie (napr.: *viditeľné v okolí OD*).

3.4 Zámer spracovania práce

Zámerom dajnej práce v nasledujúcich častiach bude postupne spracovávať dané oftalmologické obrázky (viz. *obrázky na priloženom CD k práci*). Po základných úpravách, akými boli rozdelenie obrazu na jednotlivé farebné zložky (R,G,B), jeho zmenšenie pre urýchlenie výpočtov (výberom každého 2 resp. 3 vzorku) sa prešlo k podstatným častiam práce.

Prvou úlohou k vykročeniu za detekciou výpadkov vo VNV bude detekcia OD. Tá bude vychádzať so samotnej detekcie polohy OD (konvolúcia s maskou), a následne detekovania obvodu OD pomocou navrhnutého algoritmu (houghova transformácia). Pomocou tohoto algoritmu sa bude súčasne detekovať aj širšia oblasť záujmu, ktorá sa nachádza v oblasti okolia OD. Takto získaná oblasť už bude zaujímavá pre požadovanú detekciu výpadkov vo VNV. Hodnotenie výpadkov vo VNV bude realizované na základoch štatistického porovnávania viacerých parametrov (entropia, koeficient šikmosti a strmosti histogramu, atď.). Aby výsledky týchto štatistických parametrov boli čo najpresnejšie a tým aj dôveryhodné, bude nutné danú oblasť ďalej spracovávať.

Následným spracovaním danej oblasti bude prevod z polárnych súradníc do kartézskych, kde spracovanie bude pokračovať segmentáciou a prahovaním obrazu. Aby objekty (cievy), ktoré budeme segmentovať resp. prahovať boli čo najzreteľnejšie v obraze, využijeme lokálne zvyšovanie kontrastu. Z doposiaľ známych teoretických poznatkov vieme, že lokálne zvýrazňovanie kontrastu zavádza do obrazu aj šum, tým sa môže naskytnúť nutnosť filtrácie obrazu. V prípade potreby použijeme teda nejaký druh filtru (Gaussov alebo medianový filter). Pre samotnú segmentáciu resp. prahovanie využijeme nadobudnuté teoretické poznatky pre jednotlivé druhy metód.

Takto upravený obraz už bude možné hodnotiť na výpadky vo VNV. Ako bolo vyššie spomenuté, hodnotenie výpadkov vo VNV bude na základe štatistických parametrov. Vieme, že nervové vlákna sa prejavujú svetlým žíhaním v obraze. Oblasť výpadku preto spoznáme tak, že toto svetlé žíhanie v istej oblasti chýba alebo je menšie oproti okolitému. Detekcia týchto výpadkov bude spočívať v porovnávaní zdravej oblasti (bez výpadku vo VNV) a poškodenej oblasti (oblasť s výpadkom vo VNV). V každej oblasti si vyberieme určitý rovnaký počet vzorkov ($N \times N$ rozmeru) a v nich bude uskutočnený výpočet štatistických parametrov. Na základe takto získaných parametrov bude vidieť jednotlivé rozdiely parametrov medzi zdravou a poškodenou oblasťou. Čím budú rozdiely väčšie, tým je aj väčší predpoklad miery poškodenia VNV.

4 Detekcia optického disku

Pre detekciu OD (viz. *Obrázok č.5*) existuje viacero metod (napr.: *pomocou stredného rozptylu, konvolúcie s maskou*), ale táto práca sa bude zameriavať na detekciu pomocou konvolúcie s maskou [2]. Už z názvu je zreteľné, že táto metóda využíva konvolúciu k hľadaniu OD.


Využívané budú taktiež poznatky o polohe OD v nasnímanom obraze, čo umožní zabrániť nespravnej detekcii polohy OD. Je známe, že OD sa nachádza približne v stredovej línii horizontálnej roviny, zatiaľ čo pre vertikálnu rovinu sa nachádza mimo stredovej línie vždy v jednej z polrovín (pre pravé oko v pravej polrovine, pre ľavé oko v ľavej polrovine).

4.1 Lokalizácia OD konvolúciou

Konvolúcia je stručne povedané posúvanie masky (konvolučnej masky) po obraze. Princíp spočíva v tom, že každý pixel obrazu prekrytý maskou je vynásobený koeficientom v príslušnej bunke masky a prevedený na súčet všetkých týchto hodnôt. Tým dostávame jeden nový pixel. Posúvaním masky po celom obraze dostávame kompletný výstupný obraz. Matematicky povedané, konvolúcia je matematický operátor zpracúvajúci dve funkcie. Diskrétna konvolúcia v obraze má teda tvar (*vzorec 6*):

$$f(i, j) * h(i, j) = \sum_{m=-k}^k \sum_{n=-k}^k f(i-m, j-n) \cdot h(i, j) \quad (6)$$


Využitím výpočtu konvolúcie bude hľadaný stred OD. Ten nachádzame ako bod maxima výstupu konvolúcie obrazu (G + B složka) s maskou. Masky je navrhnutá ako matica jedničiek preto, lebo hodnota jedna reprezentuje najjasnejšiu hodnotu v obraze, čiže bielu farbu (*OD je biely*). Veľkosť masky si volíme tak, aby korespondovala približne s veľkosťou OD (najjasnejším miestom). V riešenom prípade bola volená veľkosť masky 15x15.



Obrázok č.5: Detekovaný OD


4.2 Problémy lokalizácie OD

Problém lokalizácie OD nastáva pri snímkoch, kde je sietnica značne poškodená diabetesom. Takéto poškodenie sietnice sa prejavuje bielymi škvrnami (v šedotónovom obraze), čiže rovnakou farbou, akou sa prejavuje OD (viz. *obrázok 6*).




Obrázok č.6: Snímok (G+B zložka) sietnice poškodenej diabetesom

Pre vyriešenie tohoto problému boli použité na zaistenie presnej lokalizácie základné poznatky o polohe OD. Tieto poznatky umožňujú pracovať iba s výrezom snímku (viz. *obrázok č.7*). Výrez je tvorený od stredovej línie horizontálnej roviny a to tak, že nahor aj nadol od stredovej línie berieme 1/5 veľkosti celého snímku. Zbavíme sa tak 3/5 plochy (sietnice), na ktorej by sa mohli vyskytovať poškodenia diabetesom, a ktoré by mohli spôsobiť nepresnú lokalizáciu OD. Tým ale problém nie je úplne vyriešený. Poškodenia diabetesom sa môžu vyskytovať aj v nami ponechanom výreze snímku. Tu bude ako opatrenie slúžiť to, že vyberieme *medián* hodnotu z bodov maxim výstupu konvolúcie obrazu (G + B zložka) s maskou (viz. *obrázok č.8*).




Obrázok č.7: Výrez snímku (G+B zložka) sietnice poškodenej diabetesom



Obrázok č.8: Výber median hodnoty z bodov maxím výstupu konvolúcie obrazu s maskou

Nemenej dôležitým parametrom pri predchádzaní nesprávnej lokalizácii OD je veľkosť masky (viz. obrázok č.9). Ako už bolo spomenuté, volená veľkosť masky je 15x15. Toto nastavenie ale nie je zaväzujúce, treba pri ňom hľadať aj na okolité aspekty vyskytujúce sa v obraze. Tým, že poškodenia diabetesom sa prejavujú v obraze ako škvrny s rovnakou farbou akú má OD, rozlíšiť ich bude môžeme už len na základe poznatku o tvare (veľkosti) OD. Zatiaľ čo OD je guľatý a určitej veľkosti, škvrny sú nepravidelného tvaru i veľkosti. Preto treba dôsledne dbať, aby bola veľkosť masky nastavovaná vždy s ohľadom na veľkosť OD.



Obrázok č.9: Detekcia OD s veľkosťou masky (maska 15x15 vľavo, maska 5x5 vpravo)

5 Houghova transformácia (HT)

Houghova transformácia (HT) je technika, ktorá je využívaná pre oddelenie javov daného tvaru vnútri obrazu. Pri implementácii je treba poznať analytický popis tvaru hľadaného objektu. Pretože tento prístup vyžaduje parametrický popis týchto javov, je klasická HT najčastejšie používaná pre detekciu bežných kriviek, ako sú priamky, kružnice, elipsy ap. Používa sa teda predovšetkým na segmentáciu objektov, ktorých hranice môžeme popísať jednoduchými krivkami. Hlavnou výhodou tejto metódy je robustnosť voči nepravidelnostiam a porušeniam hľadanej krivky. [2, 6]


Houghova transformácia používa k najdeniu objektov spadajúcich do danej skupiny tzv. hlasovací prístup. Hlasovanie prebieha v parametrickom priestore, v ktorom sú kandidáti objektov vybraní ako lokálne maxima v takzvanom akumulátorovom priestore, ktorý je vytvorený algoritmom HT.[6]

5.1 Houghova transformácia pre kružnicu

Definícia kružnice v ploche je daná rovnicou (7). V princípe sa jedná o dopredné a spätné mapovanie. Dopredné mapovanie vyjadruje, že pre každý bod (x,y) , ktorý leží na kružnici o strede (x_c,y_c) a polomere r platí, že vzájomná vzdialenosť bodu (x,y) a stredu (x_c,y_c) je r . U spätného mapovania sa nerozdiel od dopredného vyjadruje skutočnosť, že pre každú kružnicu, ktorá prechádza bodom (x,y) platí, že vzdialenosť jej stredu od tohoto bodu je rovná jej polomeru.

$$(x - x_c)^2 + (y - y_c)^2 = r^2 \quad (7)$$

Na týchto poznatkách môžeme byť navrhnutý generický algoritmus, ktorý bude pre každý bod F_j inkrementovať bunky (x_c, y_c, r) akumulátoru také, že $d((x_c, y_c), F_j) = r$. Tie predstavujú kružnice o stredoch vzdialených od F_j o polomere $r \in [r_{\min}, r_{\max}]$. Ak kružnica obdrží dostatočné množstvo hlasov (aspoň toľko, koľko predstavuje istá daná percentuálna časť diskretnej dĺžky jej obvodu), je vyhodnotená ako kandidát na inštanciu vstupného priestoru. Princíp HT naznačuje nasledujúci obrázok (viz. *Obrázek č.10*). [2]



Obrázok č.10: Princíp houghovej transformácie

5.2 Cannyho detektor hrán pre houghovu transformáciu

Na detekciu hrán pre neskoršie spracovávanie obrazu sa bude využívať Cannyho detektor hrán. Je považovaný za jeden z najlepších detektorov hrán. Hľadá z rôznych rozlíšení práve to najlepšie. Jeho základná myšlienka vychádza s predstavy, že skokovú hranu (v 2D obraze si ju môžeme predstaviť ako schod) je možné hľadať filtrom. Detektor je optimálny pre skokové hrany vzhľadom k trom kritériám:

1. **Detekčné kritérium** – požaduje, aby významné hrany neboli prehliadnuté a aby na jednu hranu neboli viacnásobné odozvy.
2. **Lokalizačné kritérium** – požaduje, aby rozdiel medzi skutočnou a nájdenou polohou hrany bol minimálny.
3. **Kritérium jednej odozvy** – zaisťuje, aby detektor nereagoval na jednu hranu v obraze viacnásobne. Toto čiastočne zaisťuje už prvé kritérium, ale tu je to zamerané hlavne na zašumené a nehladké hrany

Cannyho detekcia je založená na nasledujúcom postupe [2]:

- Eliminácia šumu (využíva sa Gaussov filter)
- Určenie gradientu (prvá derivácia)
- Najdenie lokálnych maxím
- Eliminácia nevýznamných hrán (prahovanie)


5.2.1 Problémy u Cannyho detektoru hrán

Najzávažnejším zisteným problémom u Cannyho detektoru hrán bola detekcia z R-zložky obrazu, v prípade, že táto zložka bola presvetlená. R-zložka nám ponúka najlepšiu viditeľnosť hrán OD, preto sa používa primárne. Vyriešenie tohoto problému bolo zrealizované pomocou prahovej hodnoty v závislosti na jase obrazu. V princípe, ak jasová hodnota (median) počtu pixelov prekročí prahovú hodnotu (v našom prípade 1000 pixelov), tak pre Cannyho detektor hrán sa bude využívať G+B-zložka obrazu namiesto R-zložky obrazu.

5.2.2 Nastavenie Cannyho detektoru hrán

K optimálnemu nastaveniu Cannyho detektoru hrán sa prišlo pomocou testovania hodnôt (prahu, rozptylu) a to pre rôzne obrázky (viz. obrázky na CD, ktoré je priložené k práci).

Čo sa týka R-zložky obrazu, tu boli zistené nasledujúce hodnoty. Hodnota rozptylu pre gaussovský filter je najvhodnejšie nastavená na 3,2 a hodnota prahu 0,155. U G+B-zložky obrazu boli zistené iné hodnoty pre správne nastavenie a to hodnota rozptylu pre gaussovský filter rovná 3,6 a hodnota prahu rovná 0,325. Pri týchto nastaveniach sa výsledky Cannyho detekcie javili najvhodnejšie. Výsledky Cannyho hranovej detekcie sú znázornené na obrázku (viz. Obrázok č.11).




Obrázok č.11: Detekcia hrán cannyho detektorom


5.3 Výsledky Houghovej transformácie (HT)

Ako už bolo zmienené (viz. *kap. 4*) táto metóda sa používa hlavne na segmentáciu objektov, v našom prípade na segmentáciu OD. Segmentujeme binárny obraz získaný cannyho detektorom hrán. Budeme vychádzať zo znalosti o možnom polomere hladanej kružnice. Na základe tejto znalosti bolo určené, že polomer kružnice nebude menší ako 30 pixelov a zároveň väčší ako 80 pixelov. Pri testovaní výsledkov HT boli získané ďalšie dôležité zistenia. Jedným z nich je aj problém presnej segmentácie OD. Tento problém sa vyskytuje predovšetkým u segmentácie z G+B zložky obrazu (30% neúspešnosť z 24 testovaných obrázkov, viz. obrázky na CD priloženého k práci), a je zapríčinený nedokonalou intenzitou OD (väčší rozptyl jasu od bielej hodnoty), alebo zasahovaným výrazných ciev vystupujúcich z OD do jeho okolia. Zasahovanie výrazných ciev do okolia OD má za následok možný vznik nadbytočných objektov segmentácie (hrán ciev). Tým môže reálne nastať nepresná segmentácia OD, reagujúca práve na tieto nadbytočné objekty. Jedným z uplatnených riešení je detekovať (cannyho detektorom hrán) iba čo najbližšiu časť v okolí OD. V našom prípade bola veľkosť okolia volená 80 pixelov na každú stranu (výsledkom štvorec 161x161) od bodu OD detekovaného konvolúciou s maskou. Následne v danej časti využívať prahovanie a Gaussov filter. Jednotlivé nastavenia týchto parametrov sú uvedené vyššie (viz. *Kap.4.2.2*). V prípade, že i tieto opatrenia nezabezpečili úplne najpresnejšiu segmentáciu OD, využijeme možnosť ručnej segmentácie OD. Tá sa zadáva pomocou kurzoru myši, kde prvým kliknutím kurzoru určujeme stred pre danú kružnicu (stred OD). Druhým kliknutím kurzoru volíme polomer kružnice (okraj OD). Pri ručnej segmentácii to chce patričný odhad oka zadávateľa. Určite je vhodnejšie zadať polomer o niečo väčší, než by mal byť malý a zasahoval by pod okraj OD.

Ďalším zistením bol poznatok o najvhodnejších typoch snímkov. Najvhodnejšími snímkami sú snímky formátu *jpg* (21 obrázkov z 24), u snímkov typu *bmp* (3 obrázky z 24) sa objavovali nepresnosti, ktoré boli v našom prípade spôsobené najmä malým rozlíšením (veľkosťou) snímku. To sa dá riešiť tak, že bude zvolený menší výrez z okolia OD. Je lepšie u oboch formátov preferovať čo najväčšie rozlíšenie. Výsledky pre jednotlivé segmentácie OD sú na nasledujúcich obrázkoch (viz. *Obrázky 12, 13*).



Obrázok č.12: Segmentácia OD houghovou transformáciou (správna)



Obrázok č.13: Segmentácia OD houghovou transformáciou (nesprávna)

Ako je vidieť zo zobrazených výsledkov segmentácie, nachádzajú sa v nej dve kružnice (ich stred je vyznačený červeným krížkom). Prvá (menšia) z kružníc vysegmentováva OD a tá druhá (väčšia) vytyčuje širšie okolie OD. Zabudovanie druhej kružnice do HT bolo zámerné, pretože pole (kruhový prstenec) medzi týmito dvoma kružnicami bude určovať oblasť pre ďalšie spracovávanie, a to pre úpravu daného obrazu, ktorý následne bude poslaný na detekciu výpadkov vo vrstve nervových vlákien.

6 Detekcia cievneho riečišťa

Lokalizácia (detekcia) cievneho riečišťa je pre nasledujúce spracovávanie a vyhodnocovanie obrazu veľmi dôležitá. Cievny sú súčasťou snímok sietnice z dôvodu toho, že pri snímaní očnej sietnice sú taktiež zachytené v dôsledku presvietenia cievnatky. Vhodnou detekciou ich teda musíme čo najviac zvýrazniť alebo z obrazu odstrániť. Na to budú slúžiť už vyššie uvedené metódy spracovania obrazu, hlavne segmentácia, prahovanie, poprípade filtrácia a lokálne zvýšenie kontrastu (viz. *kap. 5*). Pre našu prácu budeme vychádzať s poznatkou segmentácie pomocou hranových detektorov.

6.1 Hranové detektory

Hranových detektorov je v dnešnej dobe nespočetné množstvo. Preto si ďalej ukážeme iba niektoré typy. Rozlišujeme dve hlavné skupiny metód detekcie hrán. Prvá skupina metód využíva prvú deriváciu a u druhej skupiny metód je využívaná druhá derivácia. Pri použití prvej derivácie je výsledok porovnávaný s prahom, ktorý nám určuje, či sa jedná o hranu resp. nejedná o hranu. Pri užívaní druhej derivácie je zaznamenávaný výskyt hrany v tom prípade, ak je priestorová zmena v polarite druhej derivácie dostatočne významná. [9]

Daná práca sa bude zameriavať predovšetkým na prvú metódu, čiže detekciu pomocou prvej derivácie. Je pomerne jednoduchá a dáva solídne výsledky. Navyše má výhody oproti druhej metóde využívajúcej druhú deriváciu, ktorá spôsobuje dvojité odozvy na niektoré hrany v obraze. Ďalšími nevýhodami, ktoré vznikajú používaním druhej derivácie, detekujúcej prechod nulovou hladinou sú:

- Veľké vyhladenie obrazu
- Strata ostrých rohov
- Sklon vytváraný uzatvorenej slučky hrán

6.1.1 Detekcia pomocou prvej derivácie

Detekcia pomocou prvej derivácie využíva rozdiel okolných bodov (pixelov) obrazu. Najjednoduchším spôsobom je vypočítať deriváciu pre riadky alebo stĺpce zvlášť. Susedné pixeli berieme z ľava do prava (resp. zhora nadol). Výsledný gradient je daný:

$$G(i, j) = \sqrt{G_R(i, j)^2 + G_S(i, j)^2} \quad (8)$$

$G(i, j)$ je výsledný gradientný obraz, $G_R(i, j)$ je gradient obrazu po detekcii hrán pomocou prvej derivácie pre riadky a $G_S(i, j)$ je gradient obrazu po detekcii hrán pre stĺpce. Gradient vypočítame tiež ako konvolúciu filtru s obrazom. Jednotlivé hranové detektory sa následne líšia práve týmto filtrom. Jadro filtru nám stanovuje, ktoré body (pixeli) máme pre výpočet gradientu použiť a akú budú mať váhu. Nastavenie jadra (jeho veľkosť a hodnoty) nám významne ovplyvňuje výsledné vlastnosti detektoru. Ukážky niektorých typov operátorov pre osu x sú:

$$G_x = \begin{bmatrix} (1 & 0 & -1) \\ 2 & 0 & -2 \\ (1 & 0 & -1) \end{bmatrix}$$

sobel

$$G_x = \begin{bmatrix} (3 & 3 & -5) \\ 3 & 0 & -5 \\ (3 & 3 & -5) \end{bmatrix}$$

kirsch

$$G_x = \begin{bmatrix} (1 & 0 & -1) \\ 1 & 0 & -1 \\ (1 & 0 & -1) \end{bmatrix}$$

prewitt

Pre osu y sa operátor vytvorí prevedením transponovanej matice osy x. Veľkosť jadra filtru významne ovplyvňuje citlivosť na šum, a preto niektoré filtre majú veľkosť 5x5, alebo 7x7. Uvedené operátory pre hranovú detekciu boli vyvinuté heuristicky.

6.2 Výsledky detekcie cievného riečišťa


6.2.1 Prevod súradnicového systému

Pre našu detekciu cievného riečišťa bolo nutné najskôr upraviť výstupný obraz po HT. Výsledkom HT je kružnica okolo OD (*stred s, polomer r*) a následne aj druhá kružnica s rovnakým stredom, iba s väčším polomerom (vhodné voliť 3-4 x *r*), detekujúca väčšie okolie OD. Práve oblasť medzi kružnicami je pre nás zaujímavá v dôsledku pre detekciu výpadkov vo VNV. Úprava výstupného obrazu HT spočívala v prevode z polárnych súradníc do kartézkych.

Pred týmto prevodom bola nutnosť si obraz upraviť. Úprava spočívala v tom, že oblasť mimo medzikružia bola nastavená na nulu (čiže čiernu farbu) a oblasť medzikružia bola zachovaná v pôvodných hodnotách (viz. Obrázok 14). Následne takýto obraz upravujeme pomocou príkazu `pol2cart`. Ten mapuje postupne všetky body obrazu a každý z nich prepočítava z polárnych súradníc do kartézkych súradníc pomocou dvoch parametrov. Prvým je parameter *rho* a druhým *theta*. Parameter *rho* udáva vzdialenosť bodu (x_i, y_i) od stredu, zatiaľ čo parameter *theta* udáva uhol, ktorý zvierá *rho* (x_i, y_i) s kladnou x-priamkou stredu. Obidva parametre sú vyjadrené v nasledujúcich rovniciach:

$$theta = arctg\left(\frac{y}{x}\right) \quad (9)$$


$$rho = \sqrt{x^2 + y^2} \quad (10)$$




Obrázok č.14: Princíp prevodu z polárnych do kartéznych súradníc



Obrázok č.15: Obrazy detekcie v polárnych súradniciach



Obrázok č.16: Obráz pre detekciu prevedený do kartézskych súradníc




Obrázok č.17: Obráz pre detekciu prevedený do kartézskych súradníc


Prevod nám spôsobil aj neostrosti prechodu (straty, prejavujúce sa čiernymi pixelmi) niektorých pixelov v prvých a posledných riadkoch obrazu. Tento aspekt bolo nutné odstrániť, inak by spôsobil problémy pri následujúcom postupe úprav (zhoršenie kontrastu a detekcie počiatočných a koncových riadkov) obrazu (viz. *obrázok č.18*). Odstránenie spočívalo v orezaní obrazu v mieste týchto neostrosti prechodu, čiže sme sa zbavili 2-3 počiatočných a koncových riadkov.

6.2.2 Lokálne zvýraznenie kontrastu


Následným postupom bolo zlepšiť kontrast v obraze (kartézke súradnice). Na túto činnosť sme využili funkciu LZK, ktorá scela vyhovovala, ak sa dodržali zásady správneho nastavenia. V našom prípade bola volená veľkosť masky 41x41 pixelov (viz. obrázok 20). Nastavenie masky je najdôležitejším parametrom u tejto funkcie. V prípade, že nastavíme masku malú (viz. obrázok č.19), obraz nezíska dostatočné zvýraznenie kontrastu a cievy v ňom následne nemôžu byť správne detekované. Na druhej strane, nie je vhodné voliť masku ani príliš veľkú, obraz by bol nadmerne kontrastovaný, čím by vznikali falošné hrany pri následnej segmentácii obrazu (viz. obrázok 21). Jedinou nevýhodou funkcie LZK je, že zavádza do obrazu šum, ktorý ale môžeme redukovať vhodným filtrom (napr. Gaussov, medián). V práci je zvolený Gaussov filter s nastavením masky 9x9 (zabezpečuje dostatočné veľké okolie pixelov okolo objektu) a smerodatnou odchyľkou 1,2, pri ktorej sa filtrácia šumu javila najvhodnejšia.




Obrázok č.18: LZK pre neošetrené okrajové riadky



Obrázok č.19: LZK pre malú masku



Obrázok č.20: LZK pre idálnu masku



Obrázok č.21: LZK pre veľkú masku

6.2.3 Použité hranové detektory

Ako už bolo zmienené, pre hranovú detekciu využijeme metódu prvej derivácie. Vybraté boli tri druhy operátorov, ktoré boli následne testované. Výsledkom bolo zistenie ich kvality na danú detekciu hrán (v našom prípade teda ciev). Pretože bol obraz prevedený z polárnych súradníc do kartéznych súradníc, cievy nám smeruju v prevažnej miere zvisle (nie kolmo). To umožnilo využívať detekciu hrán iba pre riadkový gradient hranových detektorov (stĺpcový gradient nemal hodnotný význam pre výsledky).

Prvým operátorom bol sobelov operátor 3x3. Ako druhý bol využívaný operátor kirsch 3x3 a ako posledný je testovaný operátor prewitt 5x5. Už z veľkosti operátorov by malo byť jasné, ktorý dosahoval najlepšie výsledky vzhľadom k svojej robustnosti a tým teda aj svojej účinnosti na šum. Prvým bodom postupu pre hranovú detekciu bola konvolúcia (filtrácia) obrazu LZK s maskou jednotlivých operátorov, a to pre riadkový gradient. Tým bolo dosiahnuté ešte väčšie zvýraznenie hrán a mohlo sa teda pristúpiť k prahovaniu.

Pre prahovanie boli zvolené metódy vychádzajúce s lokálneho prahovania. Pracujú na princípe rozdelenia si obrázku na množstvo častí (lokálít), kde pre jednotlivé lokality hľadáme vhodný prah z okolia. Praktikované boli dve metódy stanovenia prahovej hodnoty z okolia, a to stredná hodnota (mean, priemer zo všetkých bodov okolia), a hodnota median (prostredná hodnota bodov okolia). Ideálnejšie výsledky dosahovala prahová hodnota určená pomocou medianu. Výsledkom prahovania bola binárna reprezentácia cievneho riečišťa, kde čierna (hodnota 0) predstavovala detekovanú cievu a biela (hodnota 1), oblasť záujmu pre

ďalší postup spracovania obrazu a to na detekciu vo VNV. Výsledky binárnej reprezentácie cievneho riečišťa pre jednotlivé operátory je vidieť na nasledujúcich obrázkoch (viz. obrázky č.22, 23, 24). Pre lepšie dosiahnutie výsledkov je možné a aj bolo využitie metódy nazývanej mean-C. Táto metóda je založená na princípe, že farba všetkých pixelov, ktoré sa nachádzajú v uniformnom okolí (tj. pozdĺž okrajov), je nastavená na farbu pozadia. Pre spomenuté uniformné okolie sa používa zvláštna prahová hodnota C. Parameter C a jeho správna voľba závisí na charakteristike obrazu, ktorý je spracovávaný. Pri našom spracovaní bolo zvolené okolie o veľkosti $w_s = 9$ (9x9) a hodnota $C = 0,07$.



Obrázok č.22: Binárny obraz operátora sobel 3x3 pre prahovanie medián




Obrázok č.23: Binárny obraz operátora prewitt 5x5 pre prahovanie medián




Obrázok č.24: Binárny obraz operátora kirsch 3x3 pre prahovanie medián

Predpoklady sa potvrdili a operátor prewitt 5x5 bol vyhodnotený najlepšie (najlepšie potlačoval šum, a najostrejšie segmentoval cievy). Nevýhodou tejto metódy je, v istých úsekoch prerušenie hrany cievy a nie úplné detekovanie robustnosti cievy (každá cieva má inú robustnosť). Vhodné by bolo doplniť výpočet detekcie algoritmom pre doplnenie chýbajúcich úsekov ciev, algoritmom pre rôzne robustnosti ciev a takisto algoritmom pre čistenie falošných štruktúr. To by zabezpečilo ešte väčšiu presnosť detekcie cievného riečišťa.


Nemenej dôležitým faktorom spracovania bolo nastavenie rozmerov binárnych obrazov pre jednotlivé hranové operátory tak, aby sa pozície detekovaných ciev zhodovali s pozíciou ciev v originálnom (pôvodnom) obraze. Splnenie tejto podmienky bolo ďalším krokom k uskutočneniu lokalizácie cievného riečišťa v originálnom obraze. Získané binárne obrazy boli násobené s originálnym obrazom a tým bolo získané cieвне riečišťa, ktoré bude v originálnom obraze reprezentované čiernou farbou (viz. obrázky č.25, 26, 27). Je treba brať polohy ciev do istej miery s rezervou, a pri výbere objektov pre detekciu výpadkov vo VNV sa snažiť vybrať objekty tak, aby do nich nezasahovala cieva ktorá by mohla spôsobiť nepresnosť štatistických údajov (najmä úseky chýbajúcich ciev, ktoré sú zásadne naviazané na detekovanú polohu ciev).



Obrázok č.25: Binárny obraz sobel vložený do originálu



Obrázok č.26: Binárny obraz prewitt vložený do originálu



Obrázok č.27: Binárny obraz kirsch vložený do originálu


7 Detekcia výpadkov vo vrstve nervových vlákien (VNV)

Problematika detekcie výpadkov vo VNV, kde pre snímanie sietnice je použitá Fundus kamera, nie je zatiaľ moc preskúmana. Veľšina prác, zaoberajúcich sa touto problematikou je zatiaľ na teoretickej úrovni bez praktických aplikácií. V poslednej dobe sa ale opäť zvyšuje úsilie o získanie hlavne praktických poznatkov k tejto problematike. Je to dané aj tým, že poslednou dobou sa zvýšila možnosť digitalne fotografovať a ďalej takéto fotografie (obrazy) spracovávať pomocou počítačových programov.

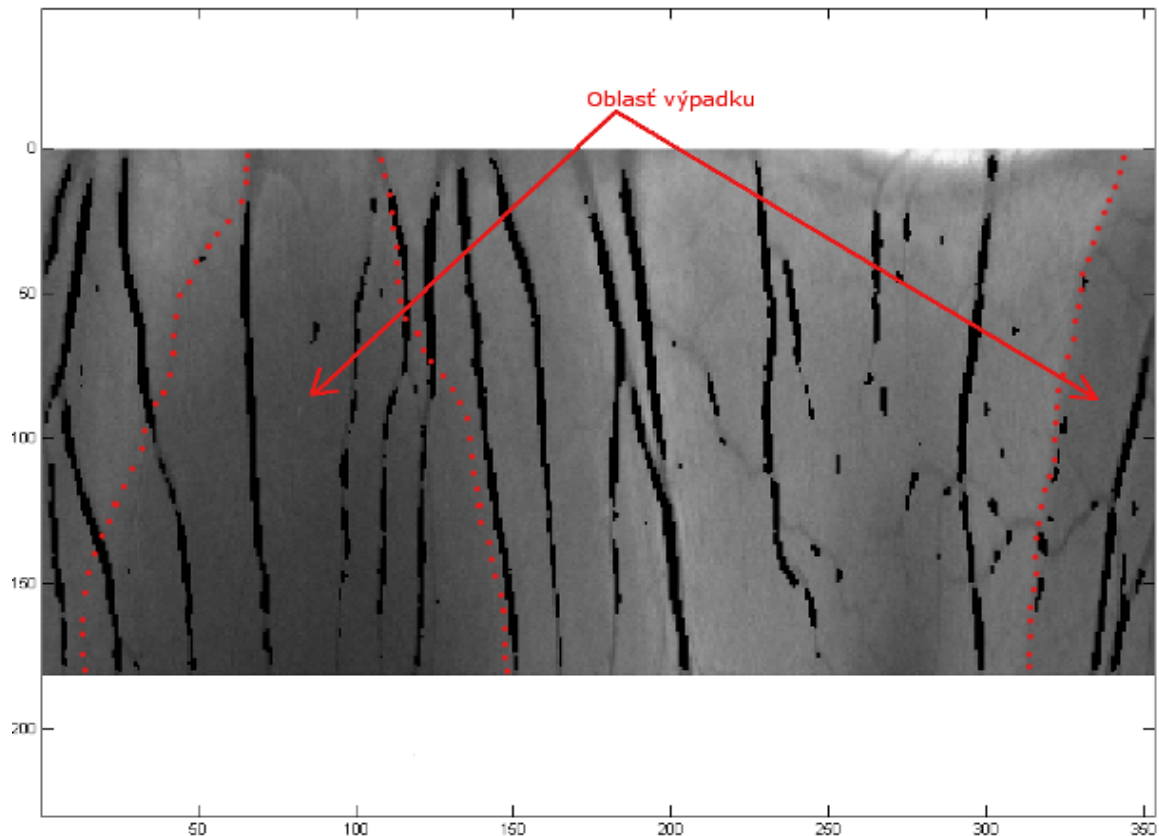
Táto práca má za úlohu preskúmať problematiku detekcie výpadkov vo VNV po teoretickej stránke a hlavne po praktickej stránke, kde budeme pomocou nadobudnutých známych poznatkov skúšať hľadať parametre, ktoré by boli vhodné pre klinické využitie. Cieľom je teda využiť digitálne Fundus kamery pre kvantitatívne hodnotenie VNV [1].

7.1 Metodika

Pre prácu boli používané farebné snímky sietnice snímané pomocou Fundus kamery Canon CF-60UV s digitálnou zrcadlovkou Canon EOS 20D. Zo získaných RGB snímok sa pracovalo iba zo zložkou GB (*modro-zelená zložka*). Na obrázku č.28 je znázornené ako vypadá oblasť bez výpadku VNV, a oblasť s výpadkom VNV v originálnom obraze. [1]




Obrázok č.28: Znázornenie oblastí výpadku VNV v originálnom obraze




Obrázok č.29: Oblasť výpadku v obraze s kartézskymi súradnicami

Začneme tým, že budeme vyberať viacero vzorkov (malé štvorčeky, viz. *Obrázok č.29*) k porovnávaniu. Musí sa dávať pozor, aby do vybraných vzorkov nezasahovalo cievne riečište, ktoré by ovplyvňovalo následné výpočty. Jednotlivé vybrané vzorky si rozdelíme na 2 skupiny pacientov (podľa oblasti výberu). Jedna skupina bude bez výpadku vo VNV (skupina A), a tá druhá bude s výpadkom vo VNV (skupina B). U očí s väčším rozsahom výpadku VNV je pozorovateľný (vyšetrením perimetrie) aj výpadok periférneho videnia.




Obrázok č.30: Výber vzorkov v oblasti výpadku VNV (červené), v oblasti bez výpadku (zelené)

Vybrané vzorky (štvorcové objekty) pre detekciu vo VNV zobrazíme jednotlivo, aby bol získaný vizuálny prehľad o jednotlivých hodnotách jasnosti pixelov. Každý pixel má inú jasovú hodnotu a tým umožňuje každý vzorok hodnotiť s rozdielnym výsledkom, ale i tak pre dané skupiny (bez výpadku resp. s výpadkom) sledovať podobnosť jednotlivých vzorkov.



Obrázok č.31: Skupina s oblasťou výpadku VNV (B)



Obrázok č.32: Skupina bez výpadku VNV (B)

Vybrané skupiny nám slúžia k tomu, aby sme našli parametre, ktoré popisujú vybrané vzorky. Ich popis by nám mal umožniť ľahké odlíšenie toho, či sa jedná o tkáň s oblasťou výpadku VNV, alebo oblasť bez výpadku VNV. Už pohľadom na jednotlivé skupiny vzorkov je vidieť, že takéto parametre budú existovať.

Aby sme tieto parametre pre jednotlivé skupiny (A, B) vzorkov tkáne získali, musíme si štatisticky vyhodnotiť parametre **lokálnych štatistík**. Jedná sa o parametre:

- Priemer odtieňov stupňov šedi - μ
- Smerodatná odchylka odtieňa šedi - σ
- Variačný koeficient **vc** ako pomer **vc** = σ / μ
- Koeficient šikmosti histogramu - γ_1
- Koeficient špičatosti histogramu - γ_2

7.1.1 Koeficient šikmosti a špičatosti histogramu


Koeficient šikmosti γ_1 je mierou súmernosti histogramu, koeficient špičatosti γ_2 je mierou strmosti histogramu.

Histogram je graf, ktorý ukazuje početnosť výskytu (*počet pixelov v danej úrovni šedi – osa y*) jednotlivých stupňov šedi (*osa x*) v danom snímku (*celkovo 256 úrovní šedi, 0-čierna, 256-biela*).


Definíciu parametrov môžeme najst' v matematických tabuľkách, alebo v menej bežnej definícii:

$$\gamma_1 = \frac{\sum_{i=1}^n x_i^3 p(x_i)}{\sigma^3} \quad (11)$$

$$\gamma_2 = \frac{\sum_{i=1}^n x_i^4 p(x_i)}{\sigma^4} - 3 \quad (12)$$



Obrázok č.33: Šikmosť histogramu



Obrázok č.34: Strmosť histogramu

Ako môžeme vidieť z obrázkov č.33, 34, tak pre koeficient šikmosti histogramu je pozitívna hodnota tohoto parametru definovaná pre významnejšie zastúpenie tmavšími pixelmi a negatívna hodnota parametru pre významnejšie zastúpenie svetlejšími pixelmi. Pre

koeficient strmosti je pozitívna hodnota definovaná pre čo najužší profil histogramu, zatiaľ čo negatívna hodnota rastie s čo najširším profilom histogramu.

7.1.2 Entropia

Entropia (mera náhodnosti) je ďalší parameter, ktorý nám umožňuje pravdepodobnostne hodnotiť výpadky VNV. Definícia tohoto parametru je:

$$E = - \sum_{i=1}^N p(x_i) \cdot \log(p(x_i)) \quad (13)$$

kde $p(x_i)$ je pravdepodobnosť, s akou sa vyskytujú úrovně šedi v snímku. N je celkový počet stupňov šedi. Pre jednotlivé skupiny (A, B) sa hodnoty stupňov šedi podstatne líšia [1].

7.1.3 Variačný koeficient

Tento koeficient predstavuje relatívnu mieru variability (odchylnosť od normalu). Používa sa predovšetkým na porovnávanie variability medzi súbormy dát s odlišnými priermi. V našom prípade nám posluží na porovnávanie odtieňov stupňov šedi. Ako už bolo v práci zmienené, variačný koeficient sa vypočíta ako:

$$v_c = \frac{\sigma}{\mu} \quad (14)$$

kde μ je priemer odtieňov šedi a σ je smerodatná odchylka stupňov šedi.

7.1.4 Smerodatná odchylka

V pravdepodobnosti a v štatistikách je smerodatná odchylka najbežnejšia miera štatistického rozptylu. Je to definícia znejúca, ako miera priemernej vzdialenosti hodnôt dát od ich priemeru. Ak sú hodnoty priestorovej značky všetky blízko priemeru, je smerodatná odchylka nízka (blížiaca sa k nule) a naopak. Smerodatná odchylka je vždy kladné číslo (alebo nula) a je vždy zameraná v rovnakých jednotkách ako originálne data.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x_{priemer})^2} \quad (15)$$

7.2 Výsledky detekcia výpadkov VNV

Ako prvé pre začatie detekcie výpadkov VNV je vybratie si vzorkov z obrazu (kartezke súradnice). Je známe že sa vyberajú vzorky do dvoch skupín. V prvej (A) budú hodnotené vzorky bez výpadku VNV zatiaľ čo v druhej skupine (B) budú hodnotené vzorky s výpadkom VNV. Z poznatkov prejavu výpadkov VNV vieme, že oblasť výpadku je jasne

tmavšia ako oblasť bez výpadku. Takto sa postupuje aj pre výber vzorkov v obraze. Pre každú skupinu bol stanovený rozsah výberu vzorkov (8). Rozsah je možné zväčšiť, ale tiež rozmer oblasti okolia OD neumožňuje vyberať vzorkov mnoho. Pomohlo by veľké rozlíšenie nasnímaných obrazov, alebo nevyberať pre urýchlenie výpočtov každý druhý vzorok obrazu v úvodnom predspracovaní. Veľkosť vzorku sme volili na 15x15 pixelov, čo by malo poskytovať dostatočnú záruku pre stabilitu jednotlivých skupín (v rámci možností pre veľkosť detekovaného okolia OD).

Výber vzorkov je realizovaný pomocou kurzoru myši, kedy kliknutím kurzoru volíme stred vzorku (čiže strednú hodnotu vzorku veľkosti 15x15). Pre zadávanie je dôležité, aby obsluhujúci dbal na dodržanie správneho zadania vzorkov pre jednotlivé skupiny. Nie je vhodné vkladať vzorky do okolia ciev, ktoré by v prípade zásahu do vzorku spôsobili znepresnenie štatistických výsledkov. Taktiež nie je doporučené zadávanie vzorkov v tesnej blízkosti okrajov obrazu. V prípade že zadávajúci predsa len zadá do vzorku oblasť cievy, je ošetrovanie tohoto problému také, že nulová hodnota jasu nie je braná do štatistických výpočtov. Vieme, že nulovou hodnotou sú vďaka detekcii cievneho riečišťa v obraze reprezentované cievy. To však nezaručuje možné zhoršenie daných štatistických parametrov (v dôsledku nie úplnej detekcie robustnosti všetkých ciev). Výsledky detekcie pre jednotlivé skupiny (A, B) a jednotlivé hodnotené obrazy sú prehľadne zobrazené v tabuľkách (viz. *tabuľky 1, 2, 3, 4, 5*). Jednotlivé grafické porovnávanie štatistických parametrov daných skupín sú zachytené na nižšie uvedených obrázkoch (viz. *obrázky 36, 37, 38*) pod príslušnými tabuľkami.

Z výsledkov sú zreteľné rozdiely hodnotených skupín (A, B). Je jasné, že priemer jasových hodnôt šedi bude vyšší u skupiny A (nepoškodené nervové vlákna sú svetlejšie). Medzi jednotlivými meraniami sa tento parameter podstatne líši (faktory nemožné ovplyvniť), preto nie je vhodný pre objektívne hodnotenie hrúbky (tlstoty) vrstvy nervových vlákien.

Naopak, už na prvý pohľad sa smerodatná odchylka javí ako vhodný parameter pre odlišenie výpadkov VNV. Popisuje veľkosť odchýliek od strednej hodnoty a tá sa práve mení v závislosti na poškodení VNV. Čím je poškodenie väčšie, tým hodnota smerodatnej odchylky klesá. Na základe týchto poznatkov vieme s časovým odstupom sledovať vývoj miery poškodenia.

Variačný koeficient naznačuje už podľa svojej definície, že nie je zrovna vhodný pre detekciu výpadkov VNV. Značne ho ovplyvňuje parameter priemer, ktorý ako bolo zmienené sa medzi jednotlivými meraniami podstatne líši.

Parameter entropie bol prekvapujúci. Predpokladalo sa, že menšie hodnoty entropie bude nadobúdať skupina B (s výpadkom), pretože porušením nervovej vrstvy sa stráca jemná štruktúra a oblasť je tak viac homogénna. Opak bol pravdou. V tomto prípade sú hodnoty entropie nižšie v skupine A (bez výpadku). Spôsobuje to malá detekčná oblasť vzorku (15x15 pixelov), v ktorej sa štruktúra nedá dobre posudzovať. Voľba väčšej detekčnej oblasti vzorkov nie je vhodná do postačujúcej miery v dôsledku hustého cievneho riečišťa v okolí OD. Napriek tomu sa dá konštatovať na základe výsledkov, že pre malú hodnotiacu oblasť je entropia vždy vyššia v oblasti s výpadkami, a teda vďaka tomu ju možno brať ako parameter docela vhodný k rozpoznávaniu poškodenia VNV.

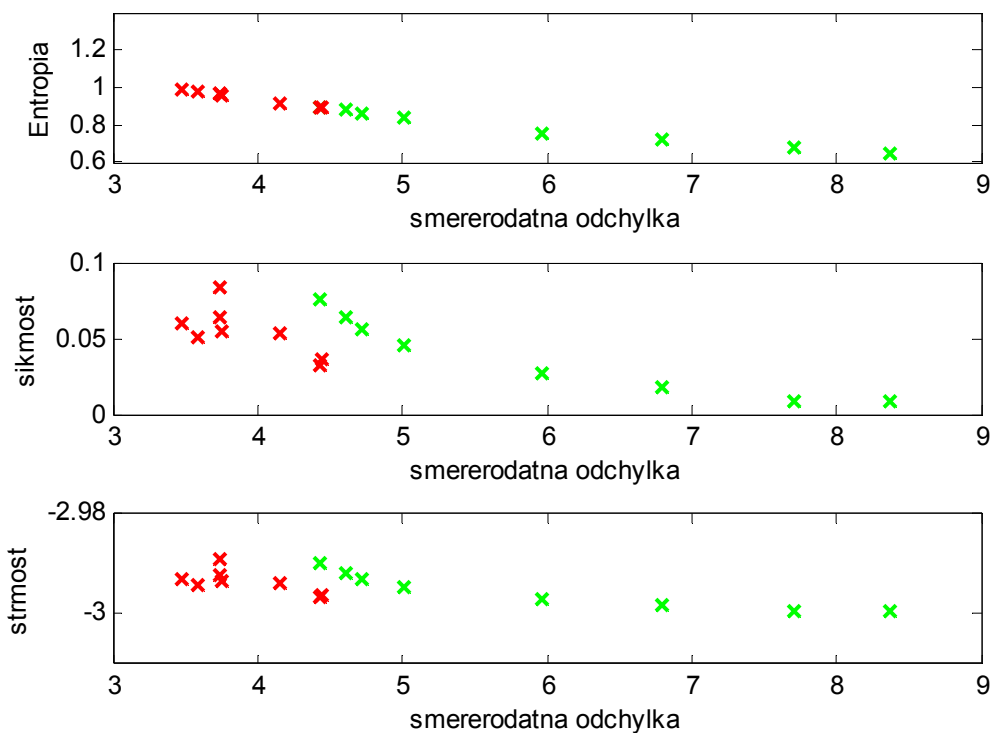
U parametrov šikmost' a špičatosť histogramu je badateľné, že výsledky nie sú dostatočne dôveryhodné pre posudzovanie rozdielov výpadkov VNV. Nemožno zaručiť stabilitu rozdielov pre jednotlivé merania. Tento problém je tiež spôsobený malou detekčnou oblasťou vzorkov (15x15 pixelov). Zvolenie väčšej detekčnej oblasti neumožňovalo husté cievne riečište v tomto okolí.

Z grafou je vidieť, že jednotlivé parametre jak pre oblasť s výpadkom, tak aj pre oblasť bez výpadku majú tendenciu sa zgrupovať pre seba charakteristických lokalitách (najmä parametre v oblasti výpadku).

7.2.1 Štatistické parametre

	prumer	smer odch	vc	sikmost	strmost	Entropia
Bez výpadku VNV (skupina A)	153,8933	4,4369	0,0288	0,0752	-2,9898	0,8948
	154,9689	4,6115	0,0298	0,0634	-2,9917	0,8783
	154,3556	5,0082	0,0324	0,0457	-2,9945	0,8361
	153,2178	4,7170	0,0308	0,0562	-2,9929	0,8645
	163,8400	5,9637	0,0364	0,0265	-2,9971	0,7592
	167,6978	6,7894	0,0405	0,0181	-2,9983	0,7280
	169,2089	8,3733	0,0495	0,0083	-2,9993	0,6512
	155,0047	7,7123	0,0498	0,0087	-2,9993	0,6760
Priemer	159,0234	5,9515	0,0372	0,0378	-2,9954	0,7860
Priem. Odch.	5,9191	1,2581	0,0070	0,0224	0,0032	0,0824
S výpadkom VNV (skupina B)	116,3467	4,4267	0,0498	0,0322	-2,9967	0,8921
	113,8044	3,7377	0,0380	0,0637	-2,9924	0,9732
	104,2756	3,5944	0,0328	0,0512	-2,9942	0,9775
	104,3556	3,4741	0,0345	0,0600	-2,9929	0,9852
	112,7733	3,7508	0,0333	0,0550	-2,9935	0,9580
	118,0889	4,4413	0,0333	0,0363	-2,9962	0,8964
	127,6356	4,1602	0,0376	0,0532	-2,9936	0,9166
	126,2133	3,7415	0,0326	0,0838	-2,9889	0,9692
Priemer	115,4367	3,9158	0,0365	0,0544	-2,9936	0,9460
Priem. Odch.	6,6344	0,3202	0,0040	0,0112	0,0016	0,0332

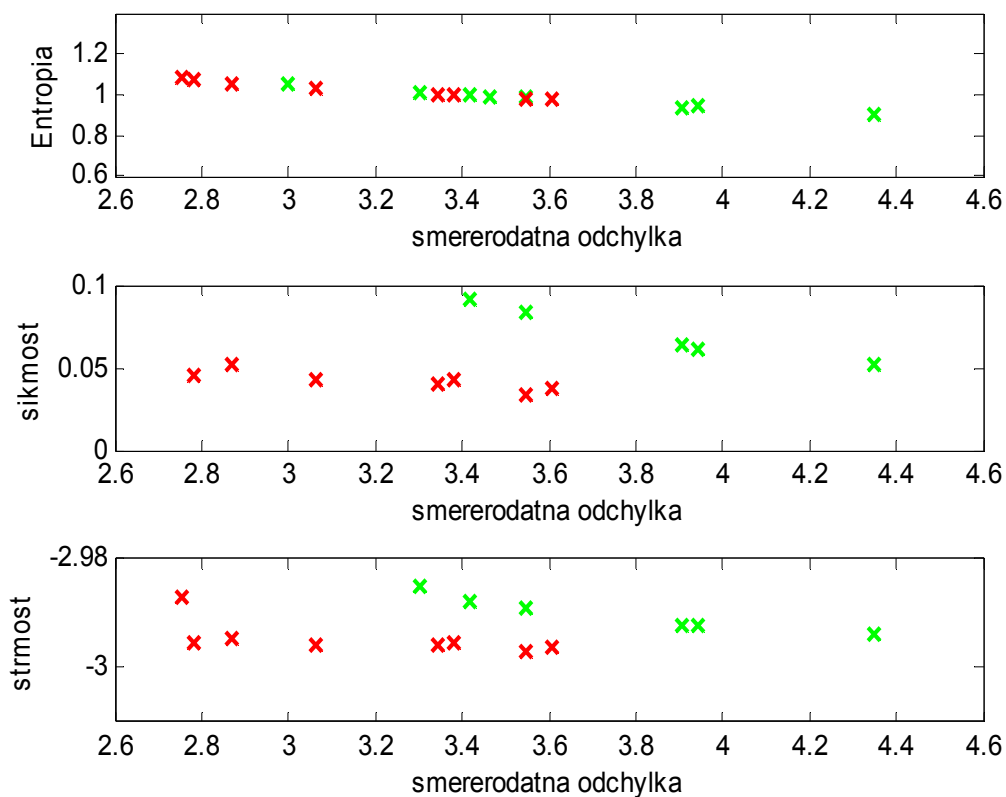
Tabuľka č.1: štatistické parametre image_2891.jpg



Obrázok č.35: graf štatistických parametrov image_2891.jpg (zelená-Skupina A, červená-skupina B)

	prumer	smer_odch	vc	sikmost	strmost	Entropia
Bez výpadku VNV (skupina A)	140,8711	3,4649	0,0246	0,1566	-2,9751	0,9916
	131,9111	4,3483	0,0330	0,0519	-2,9938	0,9043
	118,3556	3,3009	0,0279	0,1063	-2,9851	1,0102
	118,4089	3,5493	0,0300	0,0831	-2,9891	0,9853
	116,7733	3,4185	0,0293	0,0910	-2,9878	0,9960
	115,0133	3,0000	0,0261	0,1425	-2,9787	1,0567
	124,5867	3,9070	0,0314	0,0632	-2,9921	0,9378
	125,5200	3,9441	0,0314	0,0616	-2,9923	0,9463
Priemer	123,9300	3,6166	0,0292	0,0945	-2,9868	0,9785
Priem. Odch.	6,7922	0,3374	0,0023	0,0304	0,0054	0,0368
S výpadkom VNV (skupina B)	91,3689	2,7539	0,0314	0,1011	-2,9868	1,0813
	92,6756	3,6082	0,0301	0,0371	-2,9963	0,9760
	90,7911	3,3831	0,0389	0,0430	-2,9955	0,9980
	85,7600	3,3460	0,0373	0,0404	-2,9959	1,0039
	75,6622	2,8708	0,0390	0,0513	-2,9947	1,0533
	78,5333	3,0638	0,0379	0,0424	-2,9958	1,0370
	70,9422	2,7843	0,0390	0,0456	-2,9955	1,0706
	87,5733	3,5472	0,0392	0,0332	-2,9968	0,9775
Priemer	84,1633	3,1696	0,0366	0,0493	-2,9947	1,0247
Priem. Odch.	6,8381	0,3015	0,0029	0,0135	0,0020	0,0358

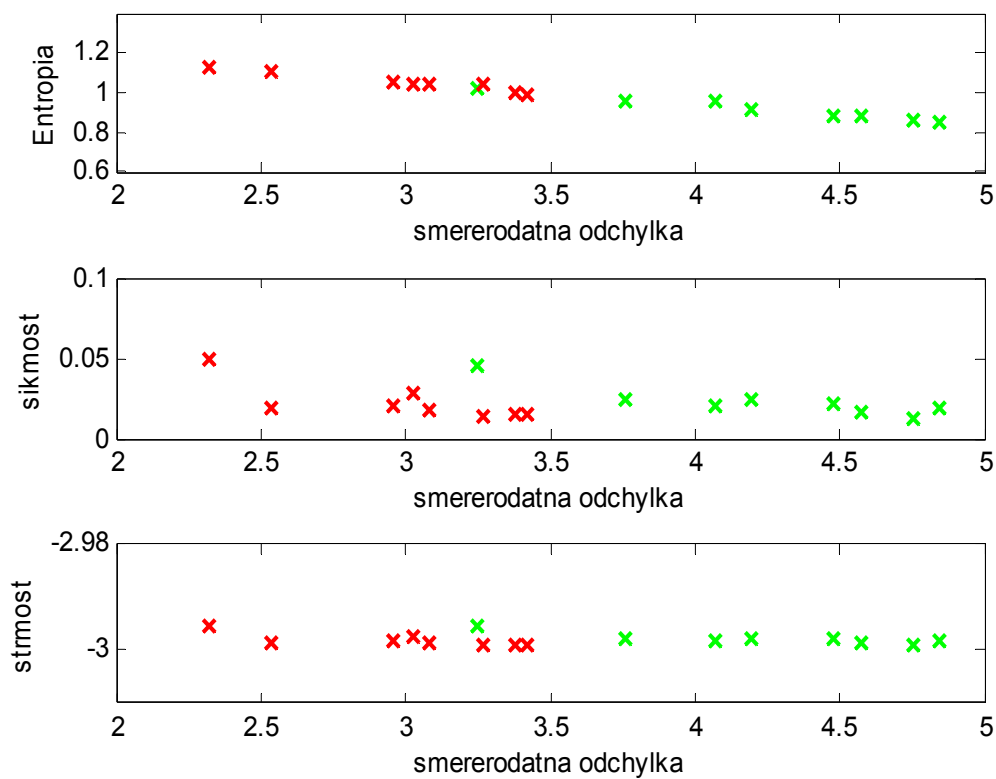
Tabuľka č.2: štatistické parametre kos1.jpg



Obrázok č.36: graf štatistických parametrov kos1.jpg (zelená-Skupina A, červená-skupina B)

	prumer	smer_odch	vc	sikmost	strmost	Entropia
Bez výpadku VNV (skupina A)	86,6222	3,7623	0,0434	0,0244	-2,9978	0,9531
	87,1378	4,0731	0,0467	0,0202	-2,9983	0,9533
	87,4044	3,2470	0,0371	0,0455	-2,9952	1,0167
	93,3511	4,7578	0,0510	0,0129	-2,9990	0,8647
	98,1156	4,5729	0,0466	0,0167	-2,9986	0,8805
	105,8578	4,4758	0,0423	0,0223	-2,9979	0,8789
	108,6489	4,8430	0,0446	0,0192	-2,9983	0,8543
	98,5867	4,1924	0,0425	0,0239	-2,9978	0,9120
Priemer	95,7156	4,2405	0,0443	0,0232	-2,9979	0,9142
Priem. Odch.	7,0867	0,4218	0,0029	0,0061	0,0007	0,0451
S výpadkom VNV (skupina B)	63,8489	3,4195	0,0425	0,0146	-2,9989	0,9894
	67,2800	3,0283	0,0536	0,0279	-2,9976	1,0425
	63,7156	3,3769	0,0450	0,0148	-2,9989	0,9993
	59,4044	3,0784	0,0530	0,0180	-2,9986	1,0397
	46,2133	2,5349	0,0518	0,0187	-2,9987	1,1036
	56,8889	2,3230	0,0549	0,0496	-2,9952	1,1243
	55,8311	3,2698	0,0408	0,0132	-2,9991	1,0407
	59,4933	2,9592	0,0586	0,0204	-2,9984	1,0546
Priemer	59,0844	2,9987	0,0500	0,0222	-2,9982	1,0493
Priem. Odch.	4,5800	0,2948	0,0054	0,0083	0,0009	0,0337


Tabuľka č.3: štatistické parametre květoňová3.jpg



Obrázok č.37: graf štatistických parametrov květoňová3.jpg (zelená-Skupina A, červená-skupina B)

	Prumer	smer_odch	vc	sikmost	strmost	Entropia
Bez výpadku VNV (skupina A)	105,0844	3,7043	0,0353	0,0485	-2,9946	0,9622
	109,5822	4,2273	0,0386	0,0319	-2,9967	0,9117
	112,0622	4,3262	0,0386	0,0321	-2,9967	0,9009
	110,0533	5,2355	0,0476	0,0134	-2,9989	0,8080
	103,7156	4,4611	0,0430	0,0255	-2,9977	0,9281
	111,8933	4,6939	0,0420	0,0213	-2,9980	0,8549
	112,7200	4,8914	0,0434	0,0190	-2,9983	0,8394
	101,2000	6,8663	0,0678	0,0036	-2,9998	0,7023
Priemer	108,2889	4,8008	0,0445	0,0244	-2,9976	0,8634
Priem. Odch.	3,7167	0,6477	0,0066	0,0101	0,0012	0,0623
S výpadkom VNV (skupina B)	62,2489	2,9228	0,0678	0,0259	-2,9978	1,0527
	57,2267	2,4562	0,0470	0,0397	-2,9964	1,1039
	55,2533	2,5600	0,0429	0,0295	-2,9975	1,1035
	56,3556	3,0372	0,0463	0,0163	-2,9988	1,0406
	48,4089	2,3574	0,0539	0,0284	-2,9977	1,1150
	45,3156	2,2965	0,0487	0,0274	-2,9979	1,1118
	58,8089	4,9642	0,0507	0,0028	-2,9999	0,8452
	54,0533	2,8405	0,0844	0,0187	-2,9986	1,0727
Priemer	54,7089	2,9293	0,0552	0,0236	-2,9981	1,0557
Priem. Odch.	4,0872	0,5357	0,0105	0,0083	0,0008	0,0571


Tabuľka č.4: štatistické parametre herman4.jpg



Obrázok č.38: graf štatistických parametrov herman4.jpg (zelená-Skupina A, červená-skupina B)

	Prumer	smer_odch	vc	sikmost	strmost	Entropia
Bez výpadku VNV (skupina A)	71,7956	2,8492	0,0397	0,0460	-2,9955	1,0571
	91,1289	5,0267	0,0552	0,0096	-2,9993	0,8370
	79,1200	3,3716	0,0426	0,0293	-2,9973	1,0059
	75,9911	3,0140	0,0397	0,0394	-2,9961	1,0524
	75,8400	2,9592	0,0390	0,0443	-2,9955	1,0471
	85,8844	5,1195	0,0596	0,0069	-2,9995	0,8309
	88,7378	4,0757	0,0459	0,0196	-2,9983	0,9276
	95,5822	4,4245	0,0463	0,0194	-2,9983	0,9315
Priemer	83,0100	3,8551	0,0460	0,0268	-2,9975	0,9612
Priem. Odch.	7,3233	0,8065	0,0058	0,0129	0,0014	0,0794
S výpadkom VNV (skupina B)	59,7511	2,4240	0,0463	0,0471	-2,9955	1,1123
	55,3511	2,8010	0,0406	0,0203	-2,9984	1,0788
	55,1467	2,6768	0,0506	0,0251	-2,9980	1,0944
	50,1511	2,1978	0,0485	0,0415	-2,9963	1,1468
	61,6444	2,5885	0,0438	0,0400	-2,9963	1,0941
	59,2889	2,4424	0,0420	0,0449	-2,9957	1,1176
	61,9822	3,0868	0,0412	0,0199	-2,9984	1,0287
	61,1200	2,8827	0,0498	0,0266	-2,9978	1,0521
Priemer	58,0544	2,6375	0,0454	0,0332	-2,9970	1,0906
Priem. Odch.	3,3786	0,2243	0,0035	0,0102	0,0011	0,0280

Tabuľka č.5: štatistické parametre houšťová3.jpg



Obrázok č.39: graf štatistických parametrov houšťová3.jpg (zelená-Skupina A, červená-skupina B)

8 Záver

Úlohou tejto práce bolo zaoberať sa detekciou výpadkov vo vrstve nervových vlákien a zhotovenie programu pre ich automatickú detekciu. Úvodom práce sa rozoberajú základne vlastnosti sietnice a jednotlivých objektov na sietnici. Je vysvetlené k čomu nervové vlákna slúžia, a v ktorých oblastiach sietnice sa najviac prejavujú.

Práca sa zameriava na detekciu výpadkov vo vrstve nervových vlákien pomocou hodnotenia cez štatistické parametre. Už s prvého pohľadu na výsledky je jasné, že pomocou týchto parametrov sa výpadky dajú detekovať a hodnotiť. Oblasť detekcie je založená na lokalizácii optického disku a jeho následnej segmentácii v obraze pomocou Houghovej transformácie. Segmentáciou je získaný obvod optického disku vytýčený kružnicou. Druhá kružnica s rovnakým stredom, akurát s väčším polomerom ako je polomer pre obvod optického disku vymedzuje oblasť záujmu, kde budú výpadky vo vrstve nervových vlákien detekované. Daná oblasť sa musí vhodne upraviť, čiže zvýšiť kontrast aby oblasti výpadku boli zreteľné, ale hlavne sa musí lokalizovať cieвне riečište, ktoré je pomerne husté a nepriaznivo zasahuje do výsledkov.

Detekcia cieвного riečišťa bola založená na segmentácii a prahovaní. Využili sa niektoré hranové detektory (sobel 3x3, prewitt 5x5, kirsch 3x3), ktoré boli vzájomne porovnávané. Zistením bolo, že je vhodnejšie používať hranové operátory s väčšími maskami, ktoré vhodnejšie segmentujú cieвне riečište. Prevodom oblasti detekčného záujmu z polárnych súradníc do kartéznych, bolo zistenie, že cievy v prevažnej miere majú vertikálny smer, a tak by nemusela byť potrebná detekcia hrán vo viacerých smeroch. Najvhodnejším riešením by bolo vyhotovenie masiek hranových detektorov tak, že by boli prispôbené pre jednotlivé profily ciev iba pre detekciu vo vodorovnom smere (vertikálny gradient). V práci vyhotovený program pracuje iba pre detekciu hrán vo vodorovnom smere. Takto upravený obraz sa prahuje, aby sa získala binárna reprezentácia cieвного riečišťa. Vhodnou metódou prahovania je metóda využívajúca lokálne prahovanie. Výhoda tohoto prahovania spočíva v tom, že prahová hodnota je hľadaná z okolia detekovaného objektu. Preto je dôležité voliť veľkosť okolia dostatočne robustne aby v nej bol zahrnutý jak hľadaný objekt, tak aj pozadie objektu. Výživné boli dve základné metódy (stredná hodnota a median). Pre lepšiu činnosť bolo prahovanie upravené pomocou hodnoty C, tzv. mean-C. Tú je treba vhodne voliť v závislosti na charakteristike obrazu. Takto pripravený binárny obraz, kde čierna farba reprezentuje cieвне riečište bol vynásobený s pôvodným obrazom, a tým sa vysegmentovali cievy v pôvodnom obraze.

Samotná detekcia je založená na porovnávaní ručne vybraných vzorkov z oblasti bez poškodenia vrstvy nervových vlákien (skupina A, v obrázkoch reprezentovaná zelene) a z oblasti poškodenia vrstvy nervových vlákien (skupina B, v obrázkoch reprezentovaná červene). V týchto vzorkoch sa porovnávali jednotlivé štatistické parametre, ktoré jasne hovoria o odlišnosti jednotlivých oblastí. U oblasti s výpadkom vo VNV majú jednotlivé parametre menšiu priemernú odchylku (viz. *tabulky č.1, 2, 3*) než v oblasti bez výpadku. Pre danú metódu sa javil vhodne parameter smerodatná ochylka, poprípade entropia. Ostatné parametre neposkytovali presvedčivé zistenia s ohľadom na výsledky. Spôsobuje to hlavne aspekt cieвного riečišťa a tým aj ovplyvnená veľkosť polí detekčných vzorkov (15x15 pixelov), do ktorých by pri zvädšení zasahovalo práve cieвне riečište. Cieвне riečište je v danej oblasti detekcie, čiže v blízkej oblasti OD, kde sa výpadky najviac prejavujú pomerne husté.

Dvoležitá pre detekciu nervových vlákien je nepochybne aj kvalita obrázkov. Je požadovaná čo možno najväčšia rozlišovacia schopnosť. Snímky taktiež nemôžu byť preexponované. Pri nadmernom osvetlení totiž hrozí, že oblasti, kde sú zdravé nervové vlákna môžu stratiť charakteristické vlastnosti.


Celkové zhodnotenie poznatkov práce hovorí o možnosti ďalšieho preskúmania tejto metódy. Pre zlepšenie výsledkov by bolo vhodné zlepšiť detekciu cievneho riečišťa pomocou segmentácie pre jednotlivé profily ciev (tenké, stredné, široké), ďalej doplnením o výpočet robustnosti ciev a ich následnému vymaskovaniu z obrazu. To by umožňovalo zvädšovať polia detekčných vzorkov, a tým aj zlepšenie výsledkov jednotlivých štatistických parametrov.

,

Zoznam použitej literatúry

- [1] KOLÁŘ R., KUBĚNA T., ČERNOŠEK P., JAN J.: *Statistická analýza vrstvy nervových vláken v barevných digitálních snímcích sítnice*, Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínckého inženýrství.
- [2] MALÍNSKÝ M.: *Segmentace významných objektů v barevných oftalmologických obrazech*, Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínckého inženýrství, 2008.
- [3] ODSTRČILÍK J.: *Analýza barevných snímků sítnice se zaměřením na segmentaci cévního řečiště*, Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínckého inženýrství, 2008.
- [4] 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 fundus photograph*, 26th Annual International Conference of the IEEE IEMBS, 2004.
- [5] VERMEER P. T., REUS N. J.: *Automated detection of wedged shaped defects in polarimetric images of the retinal nerve fibre layer*. Nature Publishing Group, 2005.
- [6] SKLÁDANKA J.: *Robotické rameno – navigace pomocí kamery Axis 214*. Vysoké učení technické v Brně, Fakulta informačních technologií, 2009 .
- [7] HANYAŠOVA L.: *Metody texturní analýzy v medicínských obrazech*. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2008.
- [8] ŠPANĚL M.: *Obrazové segmentační techniky*. Vysoké učení technické v Brně, Fakulta informačních technologií, Fakulta počítačové grafiky a multimédií, 2006.
- [9] KRUMPHOLC L.: *Metody segmentace biomedicínských obrazových signálů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních echnologií, Ústav biomedicínckého inženýrství, , 2009.

Užívateľské rozhranie



Obrázok č.41: Rozhranie funkcie *houghova_transformac*


Pre začatie programu na detekciu výpadkov VNV je funkcia *houghova_transformac* (spúšťame klasicky v Matlabe F5). Užívateľské prostredie je na obrázku nad textom (viz. obrázok č.41). Stručný popis ovládania je nasledujúci:

V hornej lište pomocou *load* sa načíta obrázok z knihovny. Pre jeho zobrazenie stlačíme tlačítko *načítanie obrázku*. V zobrazovacom poli (veľké pole) sa načítaný obrázok zobrazí.

Následne sa nastaví všetky parametre (*-MASK-*, *-OKOLIE-*, *-VELKOST R-*). Ak sa niektorý s parametrov nenastaví, program nebude pracovať. Jednotlivé hodnoty každého z parametrov sú v roletkovom menu navolené. Pre testované obrázky (viz. CD priložené k práci) je ideálne nastavenie parametrov nasledujúce:

- MASK- 15x15 (malá maska nevhodná pre obrázky s poškodením diabetes)
- OKOLIE- 80 (vhodné voliť podľa veľkosti OD a veľkosti obrázku)
- VELKOST R- 3-4 (5 ojedinele pre obrázky s veľkým rozlíšením)

Opätovným stlačením tlačítka *načítanie obrázku* sa spustí výpočet a detekuje sa OD a jeho okoliem. Výsledok sa zobrazí v zobrazovacom poli. V prípade špatnej detekcie sa stlačí tlačítko *Ano* a detekcia OD sa zadáva ručne. Ak je detekcia výpočtom správna, stlačí sa tlačítko *Nie* a program sa ukončí a automaticky spúšťa nasledujúcu funkciu *pol_cart*.



Obrázok č.42: Rozhranie funkcie *pol_cart*

V rozhraní funkcie *pol_cart* po stlačení tlačítka *OBRAZEK* sa v zobrazovacom poli zobrazí výsledok detekcie OD a okolia z funkcie *houghova_transformace*. Pre začatie výpočtu musia byť opäť nastavené všetky parametre. Ich ideálne nastavenie pre testované obrázky je (viz. obrázok č.43) nasledujúce:


Panel 1

-maska LZK- 15x15 (roletkové menu)
 Maska Gauss 7-15 (volí sa ručne)
 Sigma 1.1-1.5 (volí sa ručne)

Panel 2

-operátor- prewitt (roletkové menu)
 Mean C 0.07 (volí sa ručne)
 W 7-13 (volí sa ručne)
 -metoda- median (roletkové menu)

Po nastavení je výpočet spustený tlačítkom *START*. Výsledky sú zobrazené do zobrazovacieho pola (obraz oblasti záujmu v kartezkych súradniciach, filtrovaný obraz LZK, binárny obraz cievneho riečišťa, viz obrázok č.43). Parametre môžeme meniť a výpočet opakovať (vždy treba mať všetky parametre nastavené, spúšťať vždy tlačítkom *START*). Pre ukončenie stlačíme tlačítko *Detekce_VNV*. Automaticky sa spúšťa posledná funkcia pre *detekce_VNV*.

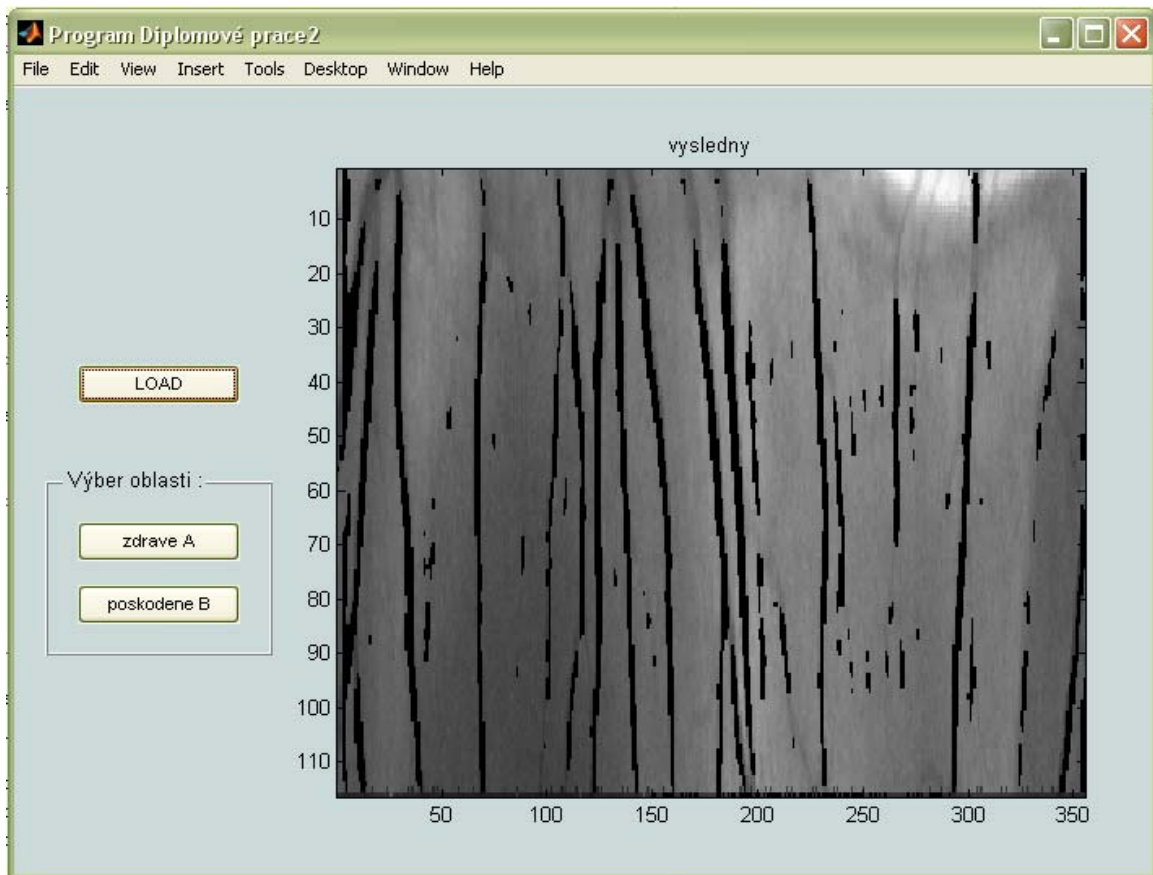


Obrázok č.43: Rozhranie funkcie *pol_cart* (výsledky po spustení výpočtu)

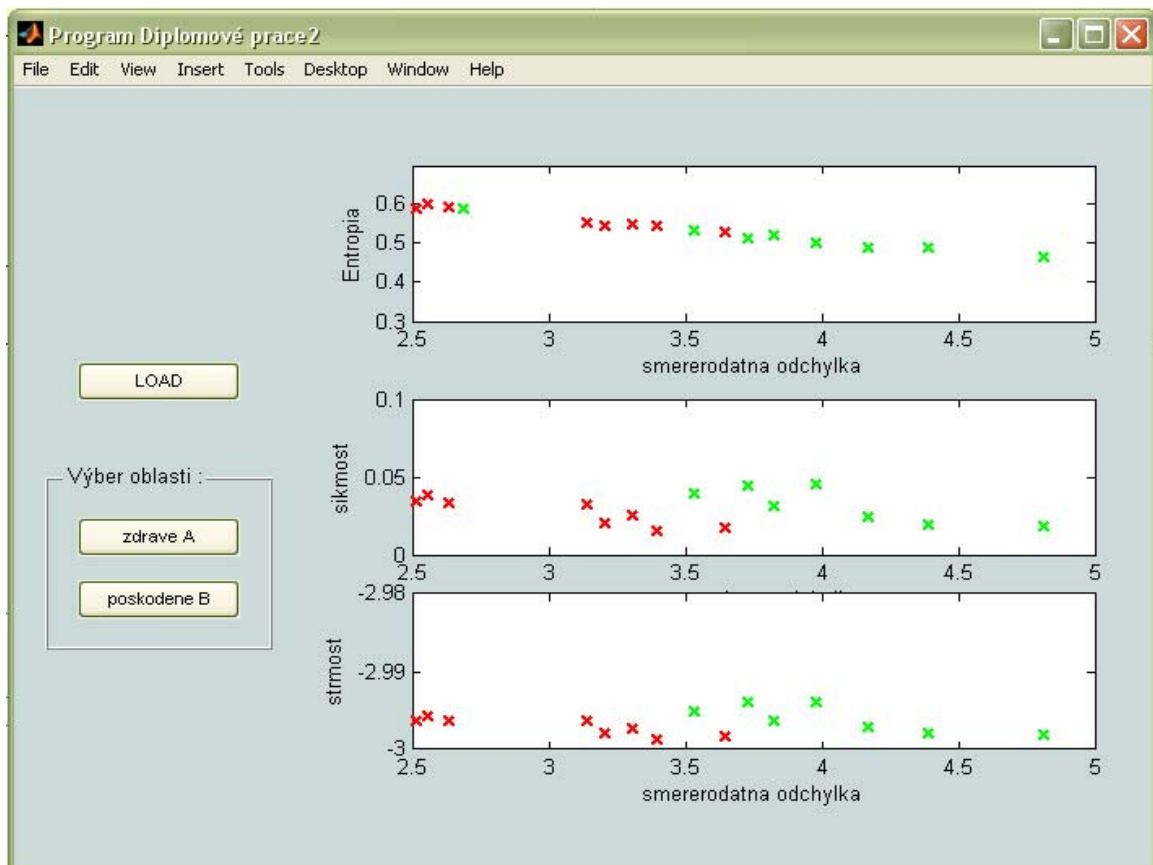
V rozhraní funkcie *Detek_VNV* zobrazíme do zobrazovacieho poľa stlačením tlačítka *LOAD* originálny obraz vynásobený s binárnym obrazom cievneho riečišťa (v kartézkyh súradniciach). Následne stlačením tlačítka *zdravé A* vyberieme ručne pomocou kurzoru 8 vzorkov (zadavame stred vzorku, kde vzorky majú rozmer 15x15 pixelov). Snažíme sa vzorky zadávať tak, aby nezasahovali do ciev. Stlačením tlačítka *poškodené B* zadáme opäť 8 vzorkov (tiež dbáme aby nezasahovali cievy).

Po zadání oboch skupín vzorkov sa automaticky spustí výpočet, ktorý zobrazí v zobrazovacom poli grafy porovnávajúce štatistické parametre (zelené – zdravé A, červené – poškodené B).

Pri skončení detekcie VNV a preskúmaní výsledkov vypíname jednotlivé rozhrania červeným krížikom v pravom hornom rohu.



Obrázok č.44: Rozhranie funkcie *Detekce_VNV*



Obrázok č.45: Rozhranie funkcie *Detekce_VNV*

Zoznam skratiek

OD – optický disk

ZS – žltá škvrna

HT – Houghova transformácia

VNV – vrstva nervových vlákien

LZK – lokálne zvýšenie kontrastu

R – červená zložka obrazu

G – zelená zložka obrazu

B – modrá zložka obrazu

G+B – zeleno modrá zložka obrazu