

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV RÁDIOELEKTRONIKY

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF RADIO ELECTRONICS

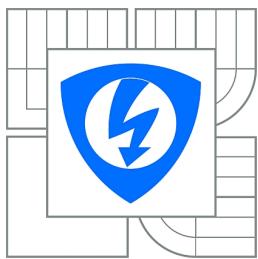
TEXTURNÍ ANALÝZA OFTALMOLOGICKÝCH SNÍMKŮ
TEXTURE ANALYSIS OF OPHTHALMOLOGIC IMAGES

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS

AUTOR PRÁCE Jan Kaňka
AUTHOR

VEDOUCÍ PRÁCE prof. Ing. Jiří Jan, CSc.
SUPERVISOR

BRNO 2010



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ
**Fakulta elektrotechniky
a komunikačních technologií**
Ústav radioelektroniky

Bakalářská práce

bakalářský studijní obor
Elektronika a sdělovací technika

Student: Jan Kaňka

ID: 106525

Ročník: 3

Akademický rok: 2009/2010

NÁZEV TÉMATU:

Texturní analýza oftalmologických snímků

POKYNY PRO VYPRACOVÁNÍ:

Seznamte se se základními typy texturní analýzy používané pro segmentaci obrazů. Dále se seznamte s vlastnostmi oftalmologických obrazů, které budou předmětem analýzy podle medicínské specifikace. Prostudujte typy texturní analýzy, které se jeví vhodné, a vybraný přístup implementujte v prostředí MATLAB. Soustředte se zejména na statistické metody založené na tzv. co-occurrence (příp. také run-length) maticích a příznacích z nich odvozených. Vytvořte aplikační program, umožňující uživatelsky pohodlnou analýzu a názornou reprezentaci výsledků, příp. také kombinující více metod. Ověřte efektivitu navrženého přístupu pro segmentaci dodaných medicínských retinálních obrazů.

DOPORUČENÁ LITERATURA:

- [1] JAN, J. Medical Image Processing, Reconstruction and Restoration. New York, London, Boca Raton, Singapore: CRC Taylor & Francis, 2006
- [2] LEE, S.Y., KIM, K.K et al. Automated quantification of retinal nerve fiber layer atrophy in fundus photograph. In Proceedings of the 26th IEEE EMBS international conference 2004, San Francisco, 2004, pp. 1241-1243.
- [3] J.Jan, J. Odstrcilík, J. Gazarek, R.Kolar: Retinal Image Analysis Aimed at Support of Early Neural-Layer Deterioration Diagnosis. In Proc. 9th Int. conf. ITAB 2009 Larnaca, Cyprus (IEEE-EMBS, IFMBE, EFMI, and ESEM), 4 pp., CD issue, ISBN 978-1-4244-5379-5.

Termín zadání: 8.2.2010

Termín odevzdání: 28.5.2010

Vedoucí práce: prof. Ing. Jiří Jan, CSc.

prof. Dr. Ing. Zbyněk Raida
Předseda oborové rady

LICENČNÍ SMLOUVA

POSKYTOVANÁ K VÝKONU UŽÍT ŠKOLNÍ DÍLO

uzavřená mezi smluvními stranami :

1. Pan / Paní

Jméno a příjmení :

Jan Kaňka

Bytem :

A. Poledníka 2/1, Ostrava - Dubina

Narozen/a (datum a místo) :
(dále jen "autor")

9. října 1986 v Ostravě

a

2. Vysoké učení technické v Brně

Fakulta elektrotechniky a komunikačních technologií
se sídlem Údolní 53, Brno, 612 00

jejímž jménem jedná na základě písemného pověření děkanem fakulty :

Prof. Dr. Ing. Zbyněk Raida, předseda rady oboru Elektronika a sdělovací technika.
(dále jen "nabyvatel")

Článek 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 : Texturní analýza oftalmologických snímků

Vedoucí / školitel VŠKP : prof. Ing Jiří Jan, CSc.

Ústav : Ústav radioelektroniky

Datum obhajoby VŠKP : _____

VŠKP odevzdal autor nabyvateli* :

- v tištění formě, počet exemplářů : 2
- v elektronické formě, počet exemplářů : 2

* Hodící se zaškrtněte

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 je identická.

Článek 2

Udělení licenčního oprávnění

1. Autor touto smlouvou poskytuje nabyvateli oprávnění (licenci) k výkonu práva uvedené dílo nevýdělečně užít, 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 tísni a za nápadně nevýhodných podmínek.
4. Licenční smlouva nabývá platnosti a účinnosti dnem jejího podpisu oběma smluvními stranami.

V Brně dne : 28. května 2010

Nabyvatel

Autor

Anotace

Tato práce se zabývá vytvořením programu pro texturní analýzu snímků retinální oblasti pomocí statistické metody co-occurrence matrices jako možnou alternativu detekce poškození sítnice glaukomem. Glaukomové onemocnění bez včasné diagnostiky a následné léčby vede k slepotě. Snímky sítnice pořízené fundus kamerou jsou běžné a velmi snadno zpracovatelné. Moderní přístroje jsou schopny zachytit snímek o rozlišení 10MPix a více, což zpřesňuje výstupy analytického software. Metoda co-occurrence analýzy je jednoduchá a velmi účinná statistika. Její nevýhodou je výpočetní náročnost, jenž přichází spolu s rostoucí objektivní kvalitou snímků.

Annotation

This thesis is concerned with creating of software for textural analysis of retinal images by statistic method called co-occurrence matrices as possible alternative method to detection of lesion of retina by the glaucoma diseases. The Glaucoma diseases without well-timed diagnostics and consequential treatment leads to blindness. The retinal images captured by fundus camera are common, easily processable and modern devices are able to make images of 10 Mpix resolution and bigger, what specifies outputs of analytic software. Method of co-occurrence analysis is simple and effective statistic. But computing demandingness, showing up with growing objective quality, comming up as disadvantage.

Klíčová slova

co-occurrence matrix, statistika, retina, sítnice, fundus kamera, oftalmologie, texturní analýza, glaukom, korelační koeficienty, entropie

Keywords

co-occurrence matrix, statistic, retina, fundus camera, ophthalmology, textural analysis, glaucoma, correlation coefficient, entropy

KAŇKA, J. Texturní analýza oftalmologických snímků. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2010. 51 s. Vedoucí bakalářské práce Prof. Ing. Jiří Jan, CSc.

Prohlášení

Prohlašuji, že svou bakalářskou práci na téma *Texturní analýza oftalmologických snímků* jsem vypracoval samostatně pod vedením vedoucího bakalářské práce, s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením tohoto projektu jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení §11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení §152 trestního zákona č. 140/1961 Sb.

V Brně dne 28. května 2010

.....
Podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce Prof. Ing. Jiřímu Janovi, CSc. za účinnou metodickou, pedagogickou a odbornou pomoc. Dále děkuji Ing. Martinu Mézlovi za odbornou pomoc a cenné rady při zpracování testovacího software. Děkuji Ing. Janu Odstrčilíkovi za zpřístupnění obrazových dat retinálních snímků.

V Brně dne 28. května 2010

.....
Podpis autora

Obsah

| | | |
|-------|--|----|
| 1 | Úvod..... | 1 |
| 2 | Anatomicko-fyziologická motivace..... | 2 |
| 2.1 | Anatomie oka..... | 2 |
| 2.2 | Anatomie sítnice..... | 3 |
| 3 | Diagnostická motivace..... | 5 |
| 3.1 | Glaukom..... | 5 |
| 3.2 | Fundus kamera..... | 6 |
| 4 | Matematický aparát..... | 8 |
| 4.1 | Motivace..... | 8 |
| 4.2 | Co-occurrence matice..... | 9 |
| 4.3 | Entropie a korelační koeficienty..... | 12 |
| 5 | Programová implementace..... | 14 |
| 5.1 | Funkce GRAYCOMATRIX implementovaná v prostředí MATLAB..... | 14 |
| 5.2 | Popis vytvořeného scriptu pro výpočet COM..... | 16 |
| 5.2.1 | Vytvoření souboru vektoru d..... | 16 |
| 5.2.2 | Výpočet COM..... | 18 |
| 5.2.3 | Výpočet korelačních koeficientů..... | 18 |
| 5.2.4 | Výpočet klasifikátorů..... | 21 |
| 6 | Výsledky analýz vybraných oblastí..... | 23 |
| 6.1 | Charakteristika funkce ECOM..... | 23 |
| 6.2 | Příklady výpočtů pro objektivně jednoznačné oblasti..... | 23 |
| 6.2.1 | Oblast s pravidelným žíháním..... | 24 |
| 6.2.2 | Oblast méně zřetelným žíháním..... | 25 |
| 6.2.3 | Oblast bez pravidelné struktury..... | 26 |
| 6.2.4 | Výřez obsahující část cévy..... | 27 |
| 6.2.5 | Oblast obsahující část cévy i s jejím centrálním reflexem..... | 28 |
| 6.3 | Shrnutí..... | 29 |
| 7 | Závěr..... | 31 |
| 8 | Použité zdroje..... | 32 |
| 9 | Seznam použitých zkratek..... | 34 |
| 10 | Seznam Příloh..... | 35 |

Seznam ilustrací

| | |
|---|----|
| Obr. 2.1: Schématický řez lidským okem | 2 |
| Obr. 2.2: Řez sítnicí..... | 3 |
| Obr. 3.1: Zdravé oko s naznačeným směrováním nervových drah..... | 5 |
| Obr. 3.2: Snímek sítnice s viditelnými výpadky nervových drah | 6 |
| Obr. 3.3: Detail oblasti s výpadkem nervových drah (označena světlým křížkem) | 6 |
| Obr. 3.4: Ilustrační fotografie fundus kamery..... | 7 |
| Obr. 4.1: Rozlišení stupňů texturní analýzy..... | 8 |
| Obr. 4.2: Nástin výpočtu co-occurrence matic..... | 10 |
| Obr. 4.3: Ukázka výběru vektoru offsetu COM..... | 10 |
| Obr. 5.1: Způsob výpočtu COM funkcí GRAYCOMATRIX..... | 15 |
| Obr. 5.2: Ilustrační snímek způsobu výběru oblastí pro porovnání..... | 16 |
| Obr. 5.3: Princip výpočtu diagonálních vzdáleností pixelů..... | 17 |
| Obr. 6.1: Oblast s pravidelným žíháním..... | 24 |
| Obr. 6.2: Grafické zobrazení hodnot v tabulce KK..... | 24 |
| Obr. 6.3: Oblast s méně zřetelným žíháním..... | 25 |
| Obr. 6.4: Grafické zobrazení hodnot v tabulce KK..... | 25 |
| Obr. 6.5: Oblast bez pravidelné struktury..... | 26 |
| Obr. 6.6: Grafické zobrazení hodnot v tabulce KK..... | 26 |
| Obr. 6.7: Vstupní snímek..... | 27 |
| Obr. 6.8: Oblast s průběhem cévy..... | 27 |
| Obr. 6.9: Grafické zobrazení hodnot v tabulce KK..... | 27 |
| Obr. 6.10: Oblast s cévou a centrálním reflexem..... | 28 |
| Obr. 6.11: Grafické zobrazení hodnot v tabulce KK..... | 28 |

1 Úvod

Glaukomová onemocnění jsou v dnešní době velmi častá. Včasná diagnóza je zásadní pro úspěšnou léčbu. Přestože existují modernější metody snímkování retinální oblasti, fundus kamera je stále nejrozšířenějším diagnostickým přístrojem v ordinacích oftalmologů. A právě tento faktor je určující pro stálý rozvoj metodiky automatických analýz retinálních snímků. Texturní analýza je pro to velmi účinný nástroj, neboť napomáhá segmentovat oblasti potenciálních výpadků nervových drah a tak upozornit ošetřujícího lékaře na možný výskyt onemocnění.

Tato práce si klade za cíl navázat na řadu prací zabývajících se metodami segmentace a analýzou retinálních snímků, vytvořit příslušný program a otestovat vhodnost analýz statistickou metodou založenou na co-occurenčních maticích pro tyto snímky. Metodika co-occurenčních matic se jeví jako výhodná, neboť je možné využít výstupy této metody pro následné kvalitativně - kvantitativní zhodnocení snímku pomocí Haralickových statistických vlastností co-occurenčních matic. V této práci je ukázána zejména vhodnost použití korelačních koeficientů pro hodnocení co-occurenčních matic. Od dalšího vývoje lze očekávat, že z těchto koeficientů by bylo možné odvodit vhodné souhrnné klasifikační příznaky pro finální diagnostiku.

Statistika co-occurrence vyžaduje poměrně kvalitní vstupní data, proto není možné provádět tuto analýzu na běžných, silně komprimovaných snímcích ani na snímcích s nízkým rozlišením. Z tohoto důvodu nebyly pro účely testování metody použity snímky formátu JPEG. Analýza snímku o typickém rozlišení 10MPix formátu BMP pak může na běžném PC probíhat v řádech jednotek až desítek minut, v závislosti na dostupném výpočetním výkonu.

2 Anatomicko-fyziologická motivace

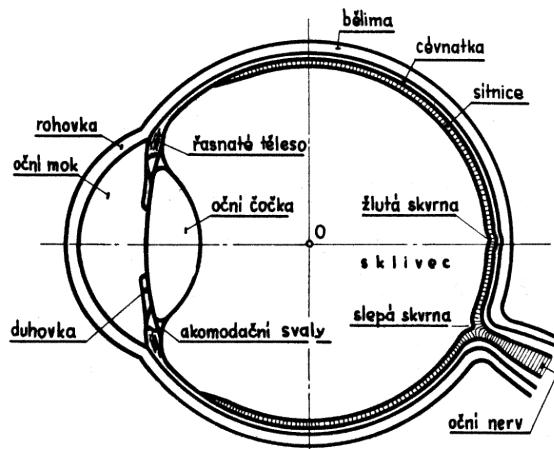
2.1 Anatomie oka

Lidské oko je složitý orgán, jenž zprostředkovává vizuální kontakt s okolním světem. Jednotlivé části vytvářejí komplexní systém (Obr. 2.1), převádějící světelné signály na signály elektrické. Ty jsou následně zpracovávány v koncovém mozku, v Brodmannově oblasti 17 v okcipitální kůře.

Stěna oka je tvořena třemi tkáňovými vrstvami:

- a) vnější – *sclera* (*bělima*), která v přední části oka přechází v *cornea* (*rohovka*).
- b) střední – *tunica vasculosa bulbi* (*živnatka*) - tu tvoří z větší části oblast bohatá na cévy - *choroidea* (*cévnatka*), dále pak místo tvorby komorové vody – *corpus ciliare* (*řasnaté těleso*) a *iris* (*duhovka*), která má za úkol regulovat množství procházejícího světla. Funkci ostřícího segmentu vykonává *lens cristalina* (*čočka*), která je ve své pozici udržována vlákny vycházejícími z *corpus ciliare*.
- c) vnitřní – vlastní světločivá vrstva *retina* (*sítnice*).

Nitrooční prostor za čočkou je vyplněn *corpus vitreum* (*sklivcem*).



Obr. 2.1: Schématický řez lidským okrem

(převzato z: http://www.pf.jcu.cz/stru/katedry/fyzika/prof/Tesar/diplomky/obr_dopl_optika/optika)

Podle Dondersova redukovaného modelu oka (kdy je celý optický systém nahrazen jedinou kulovou plochou) je optická mohutnost systému rovna 59D, jak uvádí [1].

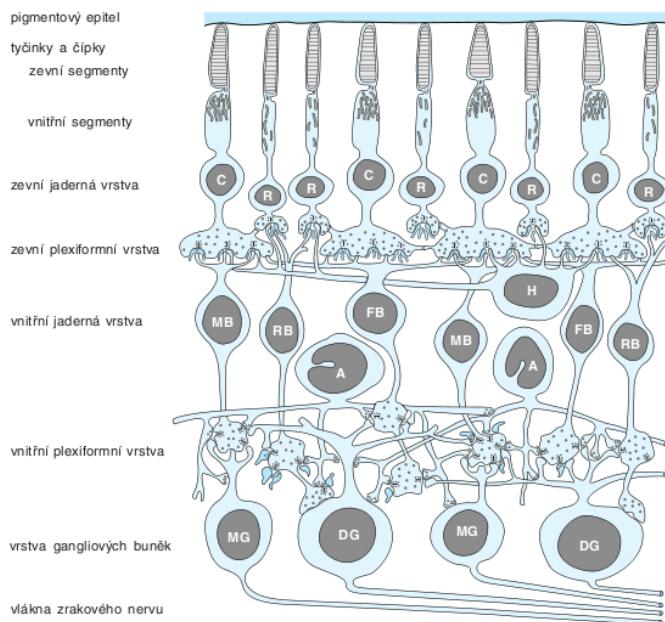
2.2 Anatomie sítnice

Sítnice oka je fotosenzitivní část celého optického systému. Svou strukturou je podobná systémům pro snímání obrazu u kamer či fotoaparátů, analogových nebo digitálních. V současné době je sítnice nenahraditelná. Je schopna například dokonalého přizpůsobení intenzitě dopadajícího světla.

Vlastní sítnice je členěna na deset vrstev, ve kterých se nacházejí světločivé receptory a čtyři druhy neuronů:

- *bipolární buňky*
- *ganglionové buňky*
- *horizontální buňky*
- *amakrinní buňky*

Světločivé receptory (dále jen SR) dělíme do dvou skupin, na tyčinky a čípky, které jsou uloženy ve vrstvě nejblíže cévnatce, pojí se s bipolárními buňkami a ty se dále napojují na buňky ganglionové, jejichž axony se sbíhají do zrakového nervu (viz Obr. 2.2). Horizontální a amakrinní buňky tvoří extracelulární pojivo a nebudeme se jimi dále zabývat.



Obr. 2.2: Řez sítnicí
(převzato z: [1])

Zkratky použité v Obr. 2.2: C - čípek, R - tyčinka, MB, RB a FB - trpasličí, tyčinkové a ploché bipolární buňky, DG a MG - difuzní a trpasličí ganglionové buňky, H - horizontální buňky, A - amakrinní buňky

Protože jsou receptory uloženy v nejhlubší vrstvě sítnice, musí světelný paprsek prostoupit vrstvou nervových vláken, ganglionovou vrstvou a vrstvou bipolárních buněk. Přes tyto vrstvy se k tyčinkám a čípkům dostane jen 10% vstupující intenzity světla. Zbylých 90% se odrazí nebo pohltí ve vyšších vrstvách. Pod SR se nachází pigmentová vrstva, která zabraňuje zpětnému odražení světelných paprsků a odděluje sítnici od cévnatky.

Oblast, kudy vystupují nervová vlákna vedoucí podráždění z SR, se nazývá *discus opticus* (*slepá skvrna*). Zde nenajdeme žádné fotoreceptory (viz Obr. 3.1).

Na zadním pólu oka se nachází *macula lutea* (*žlutá skvrna*), žlutě pigmentovaná oblast označující polohu *fovea centralis*, místa s nejostřejším viděním. Nacházejí se zde pouze čípky, a to v nadprůměrné hustotě, přičemž každý čípek vytváří synaptické spojení s jednou bipolární buňkou. Ta se pak pojí s jednou ganglionovou buňkou ze které signály směřují přímo do mozku. Fovea centralis je mírně prohloubená a jsou zde silně redukovány ostatní vrstvy. Pokud se pohled fixuje na určitý předmět, zdravé oko se pohybuje tak, aby světelné paprsky vycházející z tohoto předmětu, dopadaly přímo na fovea centralis (více viz [1] a [2]).

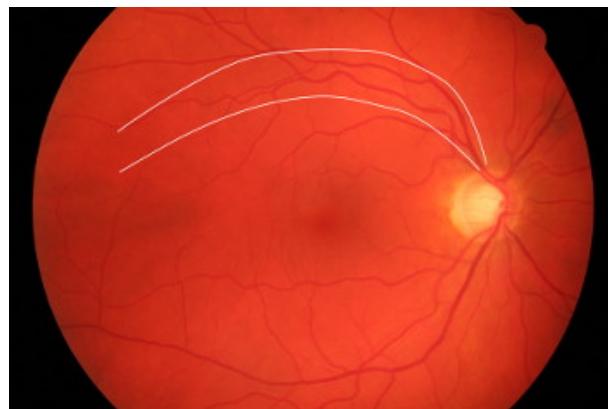
3 Diagnostická motivace

3.1 Glaukom

Podle jedné z definic je glaukom skupina chorobných stavů, při kterých je nitrooční tlak dostatečně vysoký na to, aby docházelo k poškození nervových vláken. Podle moderních poznatků však zvýšený nitrooční tlak neprovází všechny typy glaukomů, ale je jen jedním z rizikových faktorů.

Existuje několik druhů glaukomů, jejich podrobné třídění a klasifikace však není náplní této práce. Mechanismus vzniku glaukomu není přesně znám, obecně platí, že primární glaukom (tj. bez přítomnosti jiného očního nebo systémového onemocnění) je geneticky podmíněn. Neléčený glaukom vede k těžkému poškození zraku či slepotě (viz [2], [3] a [4]).

Při úbytku nervových vláken v důsledku onemocnění je možné na oftalmologických snímcích pozorovat změnu texturní struktury (jedná se o patologickou změnu, viz Obr. 3.2 a 3.3). Souběžně s odumíráním nervových vláken dochází i k odumírání ganglií a pojivových buněk, což vede k vytváření *exkavací* (*vyhloubenin*).

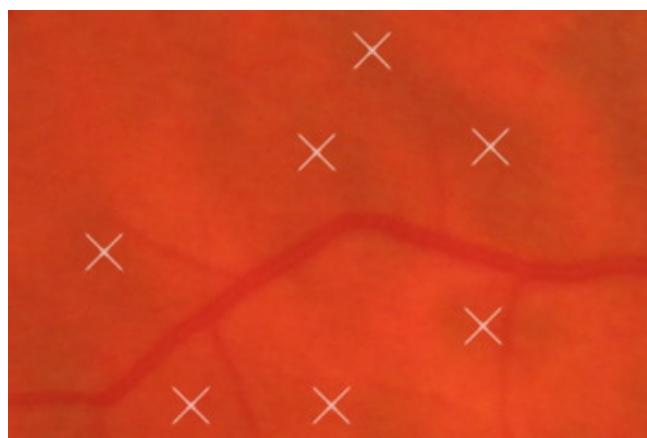


Obr. 3.1: Zdravé oko s naznačeným
směřováním nervových drah
(prevzato z archivu UBMI)



Obr. 3.2: Snímek sítnice s viditelnými výpadky nervových drah

(převzato z archivu UBMI)



Obr. 3.3: Detail oblasti s výpadkem nervových drah (označena světlým křížkem)

(převzato z archivu UBMI)

3.2 Fundus kamera

Pro včasné diagnostikování glaukomu je jako jedna z účinných metod používána fotografie optického disku tzv. *fundus kamerou* (Obr. 3.4). Jedná se o specializovaný mikroskop se záznamovým zařízením (ve formě digitálního fotoaparátu), určený k makroskopické fotografií retinální části oka.

Běžným vybavením moderních fundus kamer je vysoce citlivé záznamové zařízení s vysokým rozlišením (např. Canon CR-1 MARK II – 15.1MPix, ISO6400 ekv. kinofilm). Zorný úhel je v rozmezí 40°-60°. Moderní zařízení mohou provádět vyšetření ve více

módech, například RGB, fluorescenční, ICG, angio či stereo fotografii, jak se zmiňuje [5]. Zvláště pak ICG fotografie je při této činnosti významná, neboť na modro-zelených snímcích jsou lépe rozpoznatelné oblasti s nervovými vlákny. Pokrokem v zobrazovacích metodách je používání tzv. *non-mydriatic camera*. Jedná se o technologii umožňující retinální fotografii i bez nutnosti aplikace látek, které upravují rozšíření zornice (jako je například atropin aj.). Změnou průměru zornice oko omezuje intenzitu záření, které do něj vstupuje. Vyřazením tohoto mechanismu může dojít k sekundárnímu poškození zraku (zvláště u pacientů podstupujících oftalmoskopické vyšetření zraku opakováně).



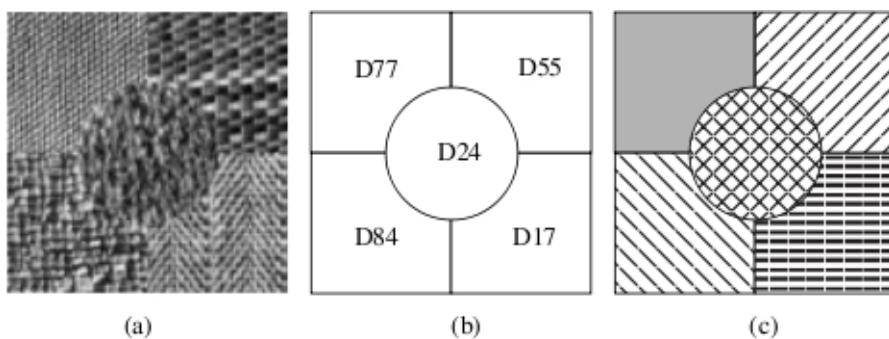
Obr. 3.4: Ilustrační fotografie fundus kamery
(převzato z: <http://www.made-in-jiangsu.com/image/2f0j00nvlEeN KanVcTM/Fundus-Camera-APS-A.jpg>)

4 Matematický aparát

4.1 Motivace

Mluvíme-li o texturní analýze, máme na mysli algoritmy, které třídí a klasifikují oblasti vizuálního vzorku dle definovaných parametrů. Reálné vzorky vesměs nejsou homogenní, naopak se skládají z rozličných vzorků, které nazýváme *vizuální textura*. Tento vzorek může být vlastností reálného povrchu – například zrnitost, hrubost, orientace vláken atd. - nebo vlastností reflekčních rozdílů, jako je tvar a barva (viz [6]).

Je vhodné definovat obrazovou texturu (Obr. 4.1.a) jako funkci prostorové proměnné intenzity odstínů šedi. Definování homogenních oblastí pak nazýváme *texturní klasifikaci* (Obr. 4.1.b), její úlohou je vytvořit jakousi mapu oblastí se stejnou, charakteristickou vlastností, jako například směr apod. Hledání hranic těchto oblastí, i přes neschopnost klasifikovat je, nazýváme *texturní třízení* (Obr. 4.1.c). Kompresní aplikace či počítačová grafika pracují s algoritmy, které z relativně mála vstupních dat vytvoří reálný obraz. Tomuto procesu říkáme *texturní syntéza*, jak se zmiňuje [6].



Obr. 4.1: Rozlišení stupňů texturní analýzy
(převzato z [6])

Ke klasifikaci vstupních dat používáme analytické a statistické metody, které nám poskytnou kompletní informaci o vlastnostech vstupního obrazu. V teorii vnímání se statistické metody dělí do dvou základních skupin:

Statistika prvního rádu: měří pravděpodobnost výskytu odstínu šedi v náhodně zvoleném pixelu. Z této definice je patrné, že se tato statistická metoda týká pouze samotného pixelu, nikoliv jeho interakcí s okolím či opakováným výskytem.

Statistika druhého rádu: měří pravděpodobnost výskytu dvou pixelů ležících na náhodně zvolené, náhodně orientované a náhodně rozměrné ose.

Na základě řešení těchto metod pak můžeme usuzovat na schopnosti rozlišení dvou příbuzných textur. Tedy zda je člověk schopen rozlišit dvě podobné textury, aniž by se na ně

cíleně zaměřil.

Řešením těchto otázek pak B. Julesz vytvořil *teorii textonů* (viz [7]), nebo-li událostí v obraze, které jsou důležité pro schopnost rozlišení. Příkladem textonů jsou rovnoběžnost, vzdálenost, zakončení, rohy apod.

Texturní analýza má široké uplatnění v oblastech zpracování obrazu. Nejběžnějším využitím je analýza lékařských obrazů, jako je MRI, PET, rentgenové snímkování či snímky z fundus kamery. Využití metod analýzy je v této oblasti široké, od vylepšování či optimalizace snímků až po automatickou diagnostiku – resp. usnadnění práce diagnostujícímu lékaři.

Další oblastí s širokým uplatněním technik texturní analýzy je oblast inspekčních procesů ve strojírenství či metalurgii. Využívá se například pro nedestruktivní defektoskopické metody nebo kontrolu jakosti a stavu výrobku.

Nemalá pozornost je věnována analytickým metodám v oblasti post-processingu obrazů, zpracování dokumentů, katalogovém vyhledávání obrazů, vzdálenému snímání (například rozlišení budov, cest, polí či vodních ploch na satelitních snímcích) aj. V oblasti počítacového vidění a robotiky je zpracování obrazu a analytická klasifikace naprosto fundamentální.

4.2 Co-occurrence matic

Metodika statistiky co-occurrence matic (COM) je v současné době zřejmě nejužívanější statistikou druhého rádu. Tato metoda vypočítává četnost výskytu páru šedo-tónových pixelů, jenž mezi sebou svírají vektor \mathbf{d} - udržují mezi sebou definovaný počet pixelových délek a jsou vůči sobě orientovány pod úhlem α . Například pro dva vektory vzdálené 3 pixelové délky pod úhlem 45° bude $\mathbf{d}=[-3 \ 3]$ (viz Obr. 4.3).

Formální předpis COM statistiky je poněkud nepřehledný, zmíním jej pouze okrajově, bez dalšího rozboru.

Nechť platí (převzato z [6]):

$$\mathbf{d} = (dx, dy); \quad (r, s), (t, v) \in N \times N; \quad (t, v) = (r + dx, s + dy)$$

pak:

$$COM(i, j) = \left\| \{(r, s), (t, v) : I(r, s) = i, I(t, v) = j\} \right\| \quad (4.1)$$

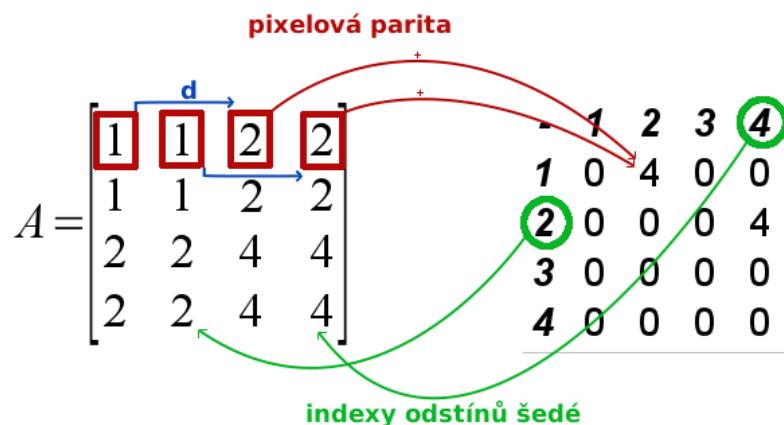
Mnohem přehlednější však bude, představíme-li si metodu pomocí příkladu. Mějme tedy obrazovou matici A rozměru 4x4 s rozpětím odstínu šedé <1,4>:

$$A = \begin{bmatrix} 1 & 1 & 2 & 2 \\ 1 & 1 & 2 & 2 \\ 2 & 2 & 4 & 4 \\ 2 & 2 & 4 & 4 \end{bmatrix}$$

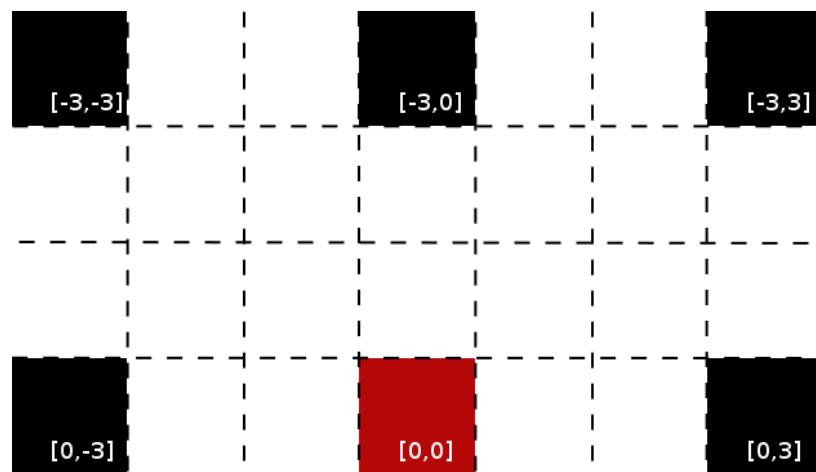
a vektor offsetu, určující vzájemnou prostorovou pozici dvou pixelů, $\mathbf{d}=[0,2]$. Pak pro COM získáme matici:

$$\begin{matrix} - & 1 & 2 & 3 & 4 \\ 1 & 0 & 4 & 0 & 0 \\ 2 & 0 & 0 & 0 & 4 \\ 3 & 0 & 0 & 0 & 0 \\ 4 & 0 & 0 & 0 & 0 \end{matrix}$$

kde indexy zapsané tučně značí šedo-tónové hodnoty jednotlivých pixelů (řádek – primární pixel, sloupec – pixel vzdálený o \mathbf{d}). Tato matice vznikla poté, co pro daný offset byly sečteny jednotlivé parity pixelů (viz Obr. 4.2).



Obr. 4.2: Nástin výpočtu co-occurrence matic



Obr. 4.3: Ukázka výběru vektoru offsetu COM

Z takto vypočtené COM jsme schopni dále vypočítat pestrou škálu vlastností obrazu. K výpočtu těchto vlastností se užívají Haralickovy statistické funkce (viz [8]).

Uvedu zde několik podstatných Haralickových vlastností COM. Jejich rozbor však není součástí této práce, proto se jimi v dalším textu nebudu blíže zabývat. Rozsáhlejší pojednání je možné nalézt v [8], [9] a [11].

Předpokládejme CO matici C, jejíž dílčí komponenty jsou $c(i,j)$. Pak platí následovné:

Střední hodnoty vypočtené přes marginální pravděpodobnosti:

$$\mu_x = \sum_{i=1}^q \sum_{j=1}^q (i) \cdot c(i, j) \quad (4.2)$$

$$\mu_y = \sum_{i=1}^q \sum_{j=1}^q (j) \cdot c(i, j) \quad (4.3)$$

Směrodatné odchylky:

$$\sigma_x = \sum_{i=1}^q \sum_{j=1}^q (i - \mu_y)^2 \cdot c(i, j) \quad (4.4)$$

$$\sigma_y = \sum_{i=1}^q \sum_{j=1}^q (j - \mu_y)^2 \cdot c(i, j) \quad (4.5)$$

Texturní entropie:

$$S = - \sum_{i=1}^q \sum_{j=1}^q c(i, j) \cdot \log c(i, j) \quad (4.6)$$

Texturní kontrast:

$$CON = \sum_{i=1}^q \sum_{j=1}^q |i - j| \cdot c(i, j) \quad (4.7)$$

Homogenita:

$$H = \sum_{i=1}^q \sum_{j=1}^q \frac{c(i, j)}{1 + |i - j|} \quad (4.8)$$

Rozložení energie:

$$E = \sum_{i=1}^q \sum_{j=1}^q c(i, j)^2 \quad (4.9)$$

Variance:

$$var = \sum_{i=1}^q \sum_{j=1}^q (i - \mu_x)^2 \cdot c(i, j) \quad (4.10)$$

Tento výčet není absolutní, je však názornou ukázkou toho, co vše lze pomocí Haralickových statistických funkcí vypočítat. Výše zmíněné vzorce byly přejaty z [8], [9] resp. [11].

4.3 Entropie a korelační koeficienty

Matice CO je prostředkem ke statistickému zpracování daného snímku. Ke kvalitativnímu zhodnocení je nutné použít výše zmíněné Haralickovy statistické funkce. V této práci jsme zvolili dva potenciálně vhodné prostředky k tomuto hodnocení.

Entropie – míra vnitřního neuspřádání snímku. Z definice vyplývá, že čím více rozdílné budou dva porovnávané pixely, tím větší bude hodnota koeficientu entropie. Testováním tohoto parametru na tréninkových snímcích – pravidelných proužkových strukturách – a následně na snímcích očního pozadí se ukázalo, že klasifikace pomocí entropie nedává dostatečně jednoznačné výsledky, aby bylo možné použít tuto metodu jako klasifikátor.

Korelační koeficient – udává lineární závislost mezi porovnávanými veličinami (pixely, obrazy atp.). Nabývá hodnot $\langle -1, 1 \rangle$, kde tyto hraniční hodnoty značí perfektní lineární vztah (převrácený nebo shodný). Nula pak značí neexistenci lineárního vztahu. V našem případě je počítán korelační koeficient mezi vztažným pixellem a pixellem určeným vektorem \mathbf{d} .

Pro výpočet korelačních koeficientů platí:

$$KK = \frac{1}{\sqrt{\sigma_x \cdot \sigma_y}} \left(\sum_{i=1}^q \sum_{j=1}^q (i \cdot j) \cdot c(i, j) - \mu_x \cdot \mu_y \right) \quad (4.11)$$

Kde $\sqrt{\sigma}$ značí směrodatnou odchylku.

Hodnota KK je skalár, jehož interpretaci ozrejmí následující tabulka:



$KK = -1$



$KK = 1$



$KK = 0$

Tato metoda byla také testována na tréninkových i reálných snímcích. Výsledné hodnoty pro oblasti pravidelných struktur byly výrazně vyšší oproti oblastem bez pravidelností (jak je ukázáno v kapitole 6.2).

K hodnocení jednotlivých COM byla proto klasifikace korelačními koeficienty vybrána. Z těchto hodnot korelačních koeficientů pak byly vypočítávány klasifikační parametry (viz oddíl 5.2.4).

5 Programová implementace

5.1 Funkce ***GRAYCOMATRIX*** implementovaná v prostředí ***MATLAB***

K řešení problematiky analýzy oftalmologických snímků pomocí COM jsem zvolil programové prostředí MATLAB. Součástí Image Processing Toolboxu je již naprogramovaný skript pro výpočet co-occurrence matic, funkce *graycomatrix*.

Funkce *graycomatrix* (dále jen GCM) vypočítává COM výše uvedeným způsobem z šedo-tónového obrazu a to na základě uživatelem zadaných podmínek. Vysvětlení a popis těchto volitelných podmínek je fundamentální pro porozumění způsobu použití této funkce.

Parametry GCM se zadávají formou struktury, tedy:

$$glcms = graycomatrix(I, 'param1', val1, 'param2', val2, \dots)$$

kde *I* je vstupní obraz, *param1*, *param2* značí volitelný parametr a *val1*, *val2* jsou hodnoty přiřazené těmto parametrům (viz [10]).

Parametry:

- | | |
|-------------------|---|
| <i>GrayLimits</i> | - jedná se o dvojrozměrný vektor [<i>l</i> , <i>h</i>], specifikující rozsah odstínů v obraze. Hodnota „ <i>l</i> “ značí dolní hraniční odstín, kde pixely s úrovní šedé menší než <i>l</i> jsou brány jako rovny <i>l</i> , a „ <i>h</i> “ značí horní hraniční odstín, kde platí, že pro pixely s úrovní šedé vyšší než <i>h</i> jsou brány jako rovny <i>h</i> . Nejsou-li ručně zvoleny hodnoty těchto hranic, funkce přiřadí <i>l</i> minimální úroveň šedé v obraze a <i>h</i> úroveň nejvyšší. |
| <i>NumLevels</i> | - celočíselná hodnota určující rozdelení úrovní šedé v obraze. Je-li například NumLevels = 8, jsou úrovně šedé v obraze škálovány do osmi hodnot. NumLevels určuje velikost výsledné COM. Chceme-li rozdělit úrovně šedé do stejněho rozpětí, jakým disponuje původní obraz, bude NumLevels typicky rovno „ <i>h</i> – <i>l</i> “. |
| <i>Offset</i> | - je pole o rozměrech Nx2, kde <i>N</i> značí počet řádků a 2 počet sloupců. Jak bylo výše definováno, vektor d určuje vzájemnou orientaci dvou pixelů. Tento vektor je dvousložkový – odtud plyne, že dvousložkový musí být i vektor offsetu fce GCM. Počet řádků pak určuje, kolikrát se bude GCM počítat, resp. pro kolik různých směrů se bude počítat. Definujeme-li vektor d jako: d = [řádky, sloupce], pak platí, že „řádky“ určují počet řádků vyčleněných mezi dvěma pixely a „sloupce“ určují počet sloupců. Z Obrázku 4.3 je možné odvodit vektorová čísla pro úhly mezi dvěma pixely rovna: $0^\circ \rightarrow [0,D]$, $45^\circ \rightarrow [-D,D]$, $90^\circ \rightarrow [-D,0]$, $135^\circ \rightarrow [-D,-D]$; je-li požadovaný počet pixelových délek „ <i>D</i> “. |
| <i>Symmetric</i> | - je zde zadávána pravdivostní hodnota true/false. Pokud je pravdivostní hodnota nastavena jako „true“, pak je zvažováno pořadí hodnot odstínu šedé, tedy hodnoty odstínů šedé parit dvou pixelů 1 – 2 se započítávají stejně jako |

hodnoty 2 - 1, hodnota 1 je přilehlá k hodnotě 2 (dochází k diagonální symetrii). Pokud je nastaveno „false“, pak se započítávají pouze hodnoty 1 – 2 nebo 2 – 1 v závislosti na zvoleném offsetu.

K jasnějšímu porozumění parametru „Symmetric“ slouží následující příklad:

Použijeme-li parametr „Symmetric“ jako „true“,

$glcms1 = graycomatrix(I, 'offset', [0 1], 'Symmetric', true)$

pak je výsledek ekvivalentní k sumě následujících dvou COM, s nastaveným parametrem „Symmetric“ jako „false“.

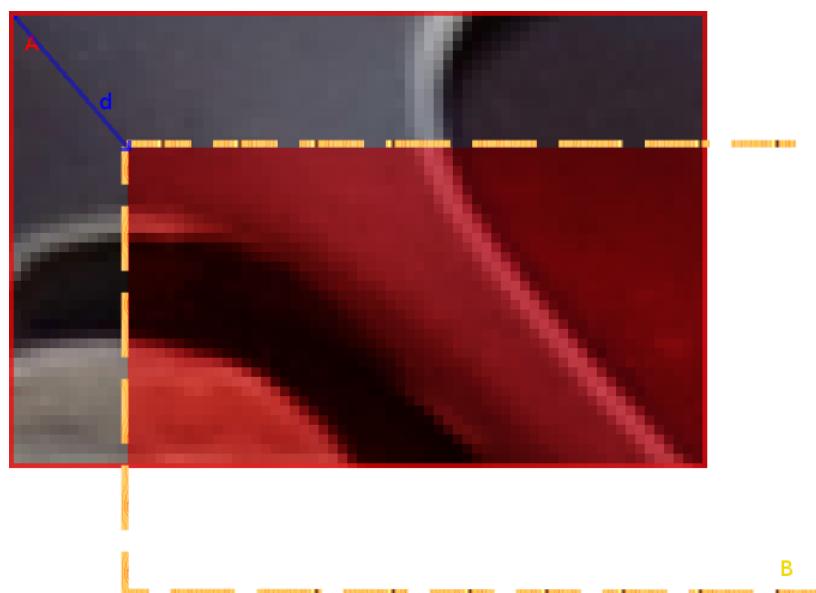
$glcms2a = graycomatrix(I, 'offset', [0 1], 'Symmetric', false)$

$glcms2b = graycomatrix(I, 'offset', [0 -1], 'Symmetric', false)$

Tedy: $glcms1 = glcms2a + glcms2b$.

(viz [10])

Zásadním nedostatkem této funkce je, že COM je vypočítávána z celého vstupního snímku a tedy pokud je $d >$ počet pixelových délek k hraně snímku, jsou tyto oblasti ignorovány a do výpočtu nejsou zahrnuty. Ignorováním okrajových částí snímku můžeme ztratit podstatnou část informace, zvláště tehdy, je-li d rádově desítky pixelů. Na obr. 4.4 je ukázán výpočet COM funkcí GRAYCOMATRIX. Pixel z oblasti A je porovnáván s pixelem v oblasti B. Jelikož je počítáno s celým snímkem, není možné zpracovávat okrajové body, neboť při posunu o d se nacházíme za hranicí snímku. Proto je z oblasti B brána pouze červeně zvýrazněná oblast. Jak již bylo zmíněno, pro rostoucí d se červená oblast zmenšuje.

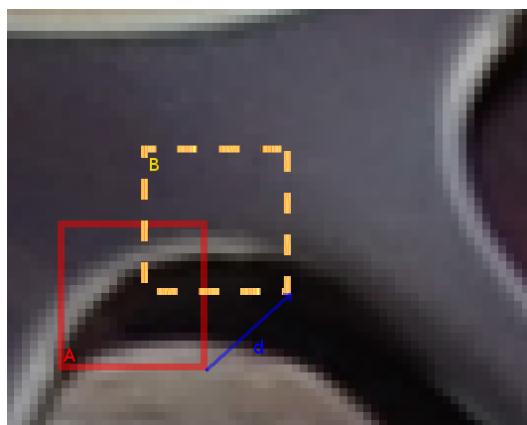


Obr. 5.1: Způsob výpočtu COM funkci GRAYCOMATRIX

Z tohoto důvodu byl naprogramován vlastní script pro výpočet COM, který se osvědčil a byl proto následně zahrnut do výpočetního scriptu namísto funkce GRAYCOMATRIX.

5.2 Popis vytvořeného scriptu pro výpočet COM

Script pro výpočet COM, jenž je zahrnut ve vlastním bakalářském programu, vychází z modifikovaného přístupu k výpočtu COM. Jak bylo zmíněno v kapitole 4.2, vyhodnocujeme šedo-tónové intenzity dvou pixelů, jejichž vzájemnou pozici určuje vektor \mathbf{d} . Mějme tedy vstupní snímek I a na něm zvolenou menší, zajímavou oblast A určenou výběrem V. Dále mějme zadaný vektor \mathbf{d} . Oblast B získáme posunem výběru V ve směru \mathbf{d} . Tím získáme dva snímky, které srovnáváme co do rozložení intenzit šedé.



Obr. 5.2: Ilustrační snímek způsobu výběru oblastí pro porovnání

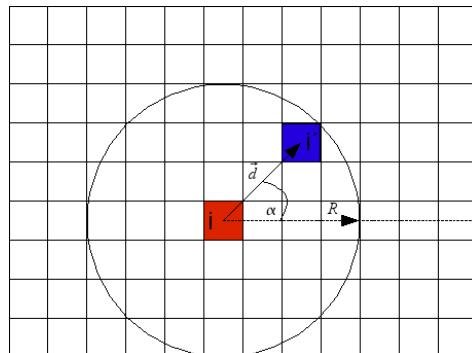
Je nutné zajistit, aby výběr V při posunu o \mathbf{d} nezasahoval za hranice vstupního snímku I. Vhodným nastavením vektoru \mathbf{d} je možné zpracovávat celý snímek bez překročení jeho hranice.

5.2.1 Vytvoření souboru vektoru \mathbf{d}

Soubor CO matice je vypočítáván pro 4 základní směry ($0^\circ, 45^\circ, 90^\circ$ a 135°), jak definoval Haralick v [9]) a pro větší soubor pixelových délek. Jak bylo zmíněno výše, průběh nervových drah na oční sítnici tvoří pravidelné struktury, jevíci se jako žihání. Tyto dráhy nezachovávají naprostou geometrickou přesnost, naopak se odchylují od jisté střední hodnoty. Proto je uživatelem zadána střední vzdálenost těchto drah formou počtu pixelových délek (R_u) a také přípustná odchylka (dR) od této střední hodnoty. Následně je vypočítáván soubor zajímavých vzdáleností $R = < R_u - dR, R_u + dR >$ s krokem „1“.

Aby byla zachována jednotná pixelová vzdálenost, je nutné vypočítávat diagonální vzdálenosti pomocí trigonometrických funkcí. Následně je vypočtená hodnota zaokrouhlena

na celé číslo (zaokrouhlení probíhá vždy na nejbližší vyšší celé číslo), aby byl brán ten pixel, jenž protíná pomyslná kružnice jednotné vzdálenosti. Na obrázku 4.6 je ukázán princip tohoto výpočtu.



Obr. 5.3: Princip výpočtu diagonálních vzdáleností pixelů

Struktura kódu je následující:

```

ofst = zeros((4*length(R)),2);
ofst_x = (-3);
for R_lev = 1:length(R)
    ofst_x = ofst_x+4;
    ofst(ofst_x,1) = 0;
    ofst(ofst_x,2) = (-R(R_lev));
    ofst(ofst_x+1,1) = (-ceil(R(R_lev)*sin(pi/4)));
    ofst(ofst_x+1,2) = (-ceil(R(R_lev)*cos(pi/4)));
    ofst(ofst_x+2,1) = (-R(R_lev));
    ofst(ofst_x+2,2) = 0;
    ofst(ofst_x+3,1) = (-ceil(R(R_lev)*sin(pi/4)));
    ofst(ofst_x+3,2) = (ceil(R(R_lev)*cos(pi/4)));
end

```

- Nejprve je vytvořena matice o dvou sloupcích a $4 \times R$ řádcích (vypočítávají se pro R vzdáleností 4 dominantní směry = $0^\circ, 45^\circ, 90^\circ, 135^\circ$)
- Dále je vytvořená proměnná (ofst_x = -3), která je v každém cyklu inkrementována o 4, čímž se zajistí, že je matice ofst naplňována od začátku do konce, nejsou tedy neustále přepisovány první čtyři pozice.
- Pro jednotlivé R jsou vypočítávány směrové vektory, pro diagonální směry je užito trigonometrických funkcí.
- Poznámka: „ceil“ je příkaz pro zaokrouhlování na nejbližší vyšší celé číslo
- Úhly posunu jsou zadávány souhlasně s GCM (tedy posun šikmo vlevo nahoru = 45° , šikmo vpravo nahoru = 135°), aby bylo možné provést přímou kontrolu.

5.2.2 Výpočet COM

Princip metody byl zmíněn v sekci 4.5. Kontrolu překročení hran snímku zajišťuje část kódu, která provádí porovnávání stávající pozice pixelu s rozměry vstupního snímku. Je-li zjištěno překročení rozsahu snímku, je výpočetní algoritmus přerušen a uživatel je o tomto stavu informován. Rozsah intenzit šedé (img_level) je analyzován v okolí zajímavé oblasti (A) tak, aby byly obsaženy všechny pixely, se kterými se pracuje.

Struktura výpočetního kódu pak je:

```
maticecom = zeros(img_lev,img_lev,length(ofst));
for vrstva = 1:length(ofst)
    for svise = svisle:svisle+vel
        for vodo = vodorovne:vodorovne+vel
            k = img(svise,vodo);
            l = img(svisle+ofst(vrstva,1),vodo+ofst(vrstva,2));
            maticecom((k-img_min+1),(l-img_min+1),vrstva) = maticecom((k-img_min+1),(l-img_min+1),vrstva)+1;
        end
    end
end
```

- Nejprve je alokována paměť tím, že jsou vytvořeny matice o rozměrech img_lev a to v počtu odpovídajícím počtu všech vektorů **d** (v kódu označeném jako ofst). Matice je formátovaná jako trojrozměrná (dva rozměry jsou definovány rozsahy šedé, třetí pak počtem jednotlivých matic).
- Následně je vytvořen pár pixelů definovaný **d**, je odečtena jejich šedo-tónová hodnota a na příslušné pozici v COM je přičtena „1“. Takto je prohledána celá zajímavá oblast i oblast k ní příslušící. Pro každý vektor **d** je proveden tento výpočet a výsledky jsou postupně ukládány do vrstev *maticecom* (hodnota v řádku ofst = **d**, číslo řádku ofst = pořadí vrstvy *maticecom*).

5.2.3 Výpočet korelačních koeficientů

Korelační koeficienty jsou vypočítávány podle vzorce 4.11, hodnoty μ a σ pak podle vzorců 4.2 (resp. 4.3) a 4.4 (resp 4.5). Tato část programu je výpočetně nejnáročnější, neboť procedura prochází všechny COM (všechny vrstvy *maticecom*) a prochází postupně všechny pixely. Je zřejmé, že bude-li stoupat počet vrstev *maticecom*, bude i čas potřebný pro kalkulaci růst. Výstupem této procedury je pak tabulka velikosti $N \times M$, kde N značí počet řádků a odpovídá jednotlivým hodnotám R , M je pak počet sloupců (tedy 4) a odpovídá jednotlivým směrům. Každá buňka pak odpovídá jednomu specifickému **d**.

Struktura procedury na výpočet korelačních koeficientů:

```

COR = 0;
my_x = 0;
my_y = 0;
sigma_x = 0;
sigma_y = 0;

cor_table = zeros(length(R),4);
for COz = 1:size(maticecom,3)

    for sub_x = 1:size(maticecom,1)
        for sub_y = 1:size(maticecom,2)
            my_x = my_x+double((sub_x)*maticecom(sub_x,sub_y,COz));
            my_y = my_y+double((sub_y)*maticecom(sub_x,sub_y,COz));
        end
    end

    for sub2_x = 1:size(maticecom,1)
        for sub2_y = 1:size(maticecom,2)
            sigma_x = sigma_x+double(((sub2_x-my_x)^2)*maticecom(sub2_x,sub2_y,COz));
            sigma_y = sigma_y+double(((sub2_y-my_y)^2)*maticecom(sub2_x,sub2_y,COz));
        end
    end
    sigma_x = sqrt(sigma_x);
    sigma_y = sqrt(sigma_y);

    for COx = 1:size(maticecom,1)
        for COy = 1:size(maticecom,2)
            COR = COR+double(COx*COy*maticecom(COx,COy,COz));
        end
    end

    mod_ind = mod(COz,4);
    if mod_ind == 0
        cor_table(ceil(COz/4),4) = ((COR-(my_x*my_y))/(sigma_x*sigma_y));
    else
        cor_table(ceil(COz/4),mod_ind) = ((COR-(my_x*my_y))/(sigma_x*sigma_y));
    end

    COR = 0;
    sigma_x = 0;
    sigma_y = 0;
    my_x = 0;
    my_y = 0;
end

```

- Je vybrána vrstva *maticecom*.
- V prvním cyklu jsou vypočítávány hodnoty μ_x a μ_y .
- V druhém cyklu je vypočtena hodnota σ_x a σ_y .
- Následně je vypočtena hodnota korelačního koeficientu dané vrstvy.
- Tento koeficient je pak uložen do příslušné buňky tabulky korelačních koeficientů, která je formátována viz výše. Formátování je prováděno na základě výpočtu hodnoty modulo(4) z pořadí zpracovávané vrstvy *maticecom*.
- Tabulka KK pak vypadá následovně:

| R | 0° | 45° | 90° | 135° |
|-------------------------------|-----------|------------|------------|-------------|
| R_u - dR | ... | ... | ... | ... |
| R_u - dR + 1 | ... | ... | ... | ... |
| R_u - dR + 2 | ... | ... | ... | ... |
| | ... | ... | ... | ... |
| R_u | ... | ... | ... | ... |
| | ... | ... | ... | ... |
| R_u + dR - 2 | ... | ... | ... | ... |
| R_u + dR - 1 | ... | ... | ... | ... |
| RU + dR | ... | ... | ... | ... |

- Tabulka KK je poté průměrována podle sloupce, aby se zabránilo skokovým změnám hodnot. Dojde k vyhlazení přechodů mezi jednotlivými řádky. Průměrování je prováděno sečtením tří po sobě jdoucích hodnot a jejich následným podělením třemi. Tato hodnota se uloží na místo první hodnoty a provádí se další průměrování. Průměrovaná tabulka je tedy o dva řádky menší než původní tabulka KK, ale hodnoty z těchto řádků jsou brány průměrovacím algoritmem, tedy nedojde k jejich ztrátě.
- Průměrovaná tabulka KK je poté zobrazena pomocí příkazu „mesh“.
- Kód průměrovacího algoritmu přikládám:

```

cor_table_avg = zeros(size(cor_table,1)-2,4);
for cor_lay = 1:size(cor_table,1)-2;
    cor_table_avg(cor_lay,1) = (cor_table(cor_lay,1)+cor_table(cor_lay+1,1)+cor_table(cor_lay+2,1))/3;
    cor_table_avg(cor_lay,2) = (cor_table(cor_lay,2)+cor_table(cor_lay+1,2)+cor_table(cor_lay+2,2))/3;
    cor_table_avg(cor_lay,3) = (cor_table(cor_lay,3)+cor_table(cor_lay+1,3)+cor_table(cor_lay+2,3))/3;
    cor_table_avg(cor_lay,4) = (cor_table(cor_lay,4)+cor_table(cor_lay+1,4)+cor_table(cor_lay+2,4))/3;
end

figure
mesh(cor_table_avg);

```

5.2.4 Výpočet klasifikátorů

Klasifikátorem je myšlen parametr sloupce tabulky, který je získán buď přímo nebo zpracováním přímo získaných hodnot. Takový parametr pak charakterizuje sloupec tabulky a na jeho základě pak rozhodujeme o tom, zda se pro daný směr a vzdálenost objevuje v zajímavé oblasti vstupního snímku žihání či nikoliv.

K hodnocení tabulky KK (v dalším textu předpokládejme, že hovoříme o průměrování tabulce KK) jsme vybrali 9 rozličných parametrů. Zpracováním statisticky relevantního souboru dat bychom měli získat jasnou představu o tom, které parametry jsou signifikantní pro rozhodnutí o existenci či neexistenci žihání ve výběru vstupního snímku. K takovému hodnocení je však nutná kontrolní sada snímků, na kterých jsou lékařem nebo ověřeným algoritmem diagnostikovány oblasti s výpadky nervových drah. Tento soubor však není v současné době v požadované kvalitě k dispozici. V následujících kapitolách proto porovnávám reakce scriptu pouze na objektivně jednoznačné oblasti.

Jako klasifikátory jsme zvolili následující parametry:

- Minimum (resp. maximum) ve sloupci (Min / Max): vyhledává se nejmenší (resp. nejvyšší) hodnota v každém sloupci.
- Prostý rozdíl (PR): provádí se prostý rozdíl maximální a minimální hodnoty v každém sloupci.
- Kladné (resp. záporné) váhování (KV / ZV): hodnota prostého rozdílu ve sloupci je zde násobena maximální (resp. minimální) hodnotou ve sloupci. Tím získáme číslo značící míru přichýlení směrem nahoru (resp. dolů). Jinými slovy nám tato hodnota dává informaci, do jaké míry je hodnota prostého rozdílu způsobena kladnou a do jaké míry zápornou hodnotou (například: bude li maximum ve sloupci = 0,2 a minimum ve sloupci = - 0,5, bude prostý rozdíl = 0,7. Kladné váhování pak = 0,14 a záporné = -0,35. Na tomto příkladu je patrné, že váhování dává poměrně jednoznačnou informaci o vnitřních vztazích ve sloupci tabulky KK). Váhování se jeví jako nejslibnější parametr pro rozhodčí algoritmus.
- Maximální (resp. minimální) hodnota z absolutních hodnot (Min abs / Max abs): nejprve je s hodnotami tabulky KK provedena operace absolutní hodnoty a poté je vyhledána maximální (resp. minimální) hodnota.
- Rozdíl absolutních hodnot (PR abs): provádí se rozdíl maxima a minima z absolutních hodnot. Tento parametr nám dává informaci, v jakém rozsahu se hodnoty ve sloupci pohybují. Pokud bude tento rozsah malý, dá se usuzovat, že pro daný směr se ve výběru nenachází pravidelné útvary (pro rozdíl absolutních hodnot → 0) nebo naopak výběr obsahuje pravidelné struktury (rozdíl absolutních hodnot → 1).
- Entropie sloupců (E): značí míru neusporádání hodnot ve sloupci. Pokud hodnoty ve sloupci sledují pravidelnou strukturu (tedy pohybují se od záporných do kladných hodnot nepříliš koncentrovaně) bude i entropie růst. Tento parametr se však jeví jako nepříliš signifikantní.

Rád bych zde zmínil část kódu pro výpočet entropie ve sloupci. Pro vlastní výpočet bylo nutné zabránit tomu, aby hodnoty v buňkách tabulky KK byly záporné. Z toho důvodu byla provedena transformace tabulky přičtením jedničky a podělením dvěma. Z původního rozsahu $<-1,1>$ na $<0,1>$. Poté byl proveden vlastní výpočet entropie sloupce pomocí vzorce 4.6.

```
cor_table_avg_shift = (cor_table_avg+1)/2;
cor_table_avg_entr = zeros(1,4);
for ctas_radky = 1:size(cor_table_avg_shift,1)
    if cor_table_avg_shift(ctas_radky,1) ~= 0
        cor_table_avg_entr(1,1) = cor_table_avg_entr(1,1)+ ...
            (double(cor_table_avg_shift(ctas_radky,1)))*log10(double(double(cor_table_avg_shift(ctas_radky,1))));
    end
    if cor_table_avg_shift(ctas_radky,2) ~= 0
        cor_table_avg_entr(1,2) = cor_table_avg_entr(1,2)+ ...
            (double(cor_table_avg_shift(ctas_radky,2)))*log10(double(double(cor_table_avg_shift(ctas_radky,2))));
    end
    if cor_table_avg_shift(ctas_radky,3) ~= 0
        cor_table_avg_entr(1,3) = cor_table_avg_entr(1,3)+ ...
            (double(cor_table_avg_shift(ctas_radky,3)))*log10(double(double(cor_table_avg_shift(ctas_radky,3))));
    end
    if cor_table_avg_shift(ctas_radky,4) ~= 0
        cor_table_avg_entr(1,4) = cor_table_avg_entr(1,4)+ ...
            (double(cor_table_avg_shift(ctas_radky,4)))*log10(double(double(cor_table_avg_shift(ctas_radky,4))));
    end
end
cor_table_avg_entr = -cor_table_avg_entr;
```

Výpočty zbylých parametrů jsou triviální a není proto nutné zde popisovat strukturu kódu výpočtů.

6 Výsledky analýz vybraných oblastí

6.1 Charakteristika funkce ECOM

Script ECOM, který byl vyhotoven jako součást bakalářské práce, je funkcí, která je spouštěna z příkazového řádku programového prostředí MATLAB a to ve formátu:

$$ECOM(inputimage,position,hrana,offset,delta)$$

- inputimage = 'požadovaný_snímek.přípona'
- position = [řádek,sloupec], tj. bod vstupního snímku který bude levým horním rohem vybrané oblasti
- hrana = celočíselná hodnota požadovaného rozlišení výběru ze vstupního snímku
- offset = R_U
- delta = dR

Výstupem tohoto scriptu je pak tabulka KK a soubor klasifikačních parametrů, které jsou vypsány do příkazového řádku prostředí MATLAB a dále jsou uloženy ve formátu *.txt do pracovního adresáře pro snazší následné statistické zpracování. Tabulka KK je zobrazena jako 3D graf typu mesh.

Script neplní funkci automatického rozhodčího systému, z toho důvodu nebyla implementována funkce automatického procházení celého snímku. Funkce ECOM primárně slouží k vytvoření statisticky významného souboru dat pro oblasti bez výpadku a s výpadkem nervových drah. Na základě tohoto souboru je pak možné vytvořit jasné klasifikační hranice a implementovat script do komplexního rozhodčího algoritmu. Z tohoto důvodu také nebylo vytvořeno GUI – funkce je snáze modifikovatelná pro okamžitou potřebu a následná implementace do komplexního rozhodčího algoritmu je tím usnadněna.

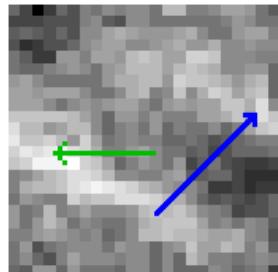
6.2 Příklady výpočtů pro objektivně jednoznačné oblasti

Každá sekce se skládá z těchto částí:

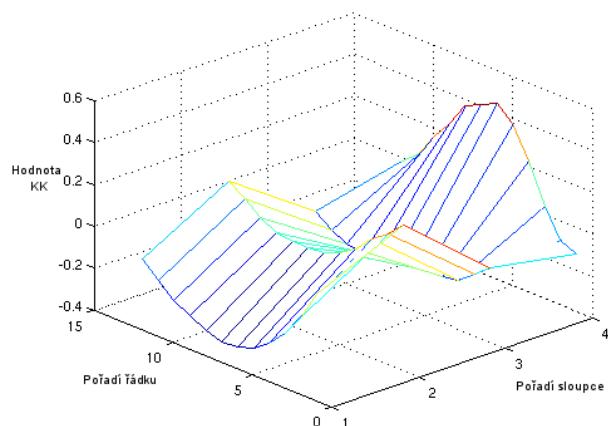
- zobrazení analyzovaného výběru
- zobrazení průměrované tabulky KK a klíčových klasifikačních parametrů
 - Červeně je označena nejvyšší a nejnižší hodnota v tabulce KK.
 - Tučně je vyznačena dominantní hodnota příslušného parametru.
- zobrazení 3D mesh grafu průběhů hodnot v tabulce KK
- slovního komentáře.

6.2.1 Oblast s pravidelným žíháním

$R_U = 12$, $dR = 7$, hrana = 22 pixel



Obr. 6.1: Oblast s pravidelným žíháním



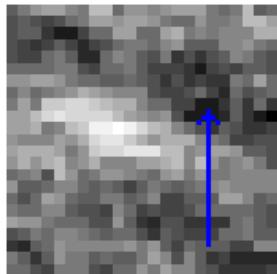
Obr. 6.2: Grafické zobrazení hodnot v tabulce KK

| R | Směr posunu | | | |
|----------------|----------------|---------------|---------------|---------------|
| | ← | ↖ | ↑ | ↗ |
| 5 | 0,1043 | 0,2963 | -0,0489 | -0,1266 |
| 6 | -0,0301 | 0,2235 | -0,1122 | -0,0901 |
| 7 | -0,1406 | 0,1687 | -0,1681 | 0,0403 |
| 8 | -0,2181 | 0,0873 | -0,1861 | 0,2267 |
| 9 | -0,2727 | 0,0376 | -0,1862 | 0,3738 |
| 10 | -0,3020 | 0,0071 | -0,1829 | 0,4421 |
| 11 | -0,3084 | 0,0037 | -0,1885 | 0,4045 |
| 12 | -0,2834 | 0,0004 | -0,2038 | 0,3669 |
| 13 | -0,2435 | 0,0112 | -0,2207 | 0,2564 |
| 14 | -0,1989 | 0,0542 | -0,2110 | 0,1558 |
| 15 | -0,1381 | 0,1164 | -0,1792 | 0,0394 |
| 16 | -0,0632 | 0,1685 | -0,1178 | -0,0166 |
| Min | -0,3084 | 0,0004 | -0,2207 | -0,1266 |
| Max | 0,1043 | 0,2963 | -0,0489 | 0,4421 |
| PR | 0,4127 | 0,2959 | 0,1718 | 0,5688 |
| KV | 0,0430 | 0,0877 | -0,0084 | 0,2515 |
| ZV | -0,1273 | 0,0001 | -0,0379 | -0,0720 |
| Min abs | 0,0301 | 0,0004 | 0,0489 | 0,0166 |
| Max abs | 0,3084 | 0,2963 | 0,2207 | 0,4421 |
| PR abs | 0,2783 | 0,2959 | 0,1718 | 0,4256 |
| E | 1,8811 | 1,7056 | 1,8977 | 1,5896 |

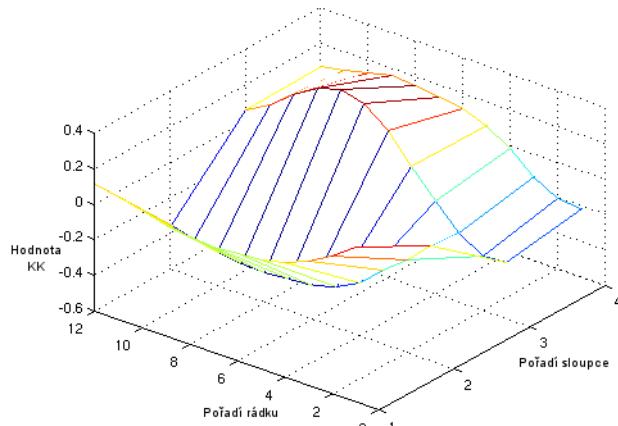
- Zde je zachycen výřez, ve kterém jsou patrné nervové dráhy formou žíhání.
- Nejvyšší hodnota je patrná pro posun 10 pixel ve směru kolmém na průběh drah (viz modrá šipka), což odpovídá předpokladu.
- Nejnižší hodnota je patrná pro posun 11 pixel ve vodorovném směru. Tím se světlé oblasti porovnávají s tmavými pruhy (viz zelená šipka).
- Parametr KV je pro sloupec s nejvyšší hodnotou o řád větší než v ostatních sloupcích.
- Parametr ZV je pro sloupec s nejnižší hodnotou o řád menší než v ostatních sloupcích.
- Hodnoty PR a PR abs jsou pro sloupec s největší hodnotou také dominantní.
- Pravidelná struktura v tomto výřezu se projevila vysokou hodnotou KK v tabulce pro vzdálenost 10 pixel, což se blíží předpokladu střední vzdálenosti dvou nervových vláken $R_U = 12$ pixel.

6.2.2 Oblast méně zřetelným žíháním

$R_U = 12$, $dR = 7$, hrana = 22 pixel



Obr. 6.3: Oblast s méně zřetelným žíháním



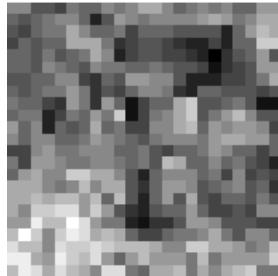
Obr. 6.4: Grafické zobrazení hodnot v tabulce KK

| R | Směr posunu | | | |
|----------------|---------------|----------------|---------------|---------|
| | ← | ↖ | ↑ | ↗ |
| 5 | 0,2717 | 0,0462 | -0,2805 | -0,2179 |
| 6 | 0,1726 | -0,0775 | -0,2909 | -0,2020 |
| 7 | 0,0984 | -0,1818 | -0,2123 | -0,1262 |
| 8 | 0,0496 | -0,3061 | -0,0754 | -0,0138 |
| 9 | 0,0165 | -0,3731 | 0,0737 | 0,0700 |
| 10 | 0,0027 | -0,4122 | 0,2227 | 0,1114 |
| 11 | -0,0062 | -0,4225 | 0,3281 | 0,1305 |
| 12 | 0,0024 | -0,4328 | 0,3661 | 0,1495 |
| 13 | 0,0205 | -0,4276 | 0,3255 | 0,1580 |
| 14 | 0,0546 | -0,4128 | 0,2385 | 0,1317 |
| 15 | 0,0859 | -0,3860 | 0,1394 | 0,0980 |
| 16 | 0,1141 | -0,3556 | 0,0595 | 0,0700 |
| Min | -0,0062 | -0,4328 | -0,2909 | -0,2179 |
| Max | 0,2717 | 0,0462 | 0,3661 | 0,1580 |
| PR | 0,2779 | 0,4789 | 0,6570 | 0,3758 |
| KV | 0,0755 | 0,0221 | 0,2405 | 0,0594 |
| ZV | -0,0017 | -0,2073 | -0,1911 | -0,0819 |
| Min abs | 0,0024 | 0,0462 | 0,0595 | 0,0138 |
| Max abs | 0,2717 | 0,4328 | 0,3661 | 0,2179 |
| PR abs | 0,2693 | 0,3866 | 0,3066 | 0,2041 |
| E | 1,7331 | 1,8734 | 1,6732 | 1,7583 |

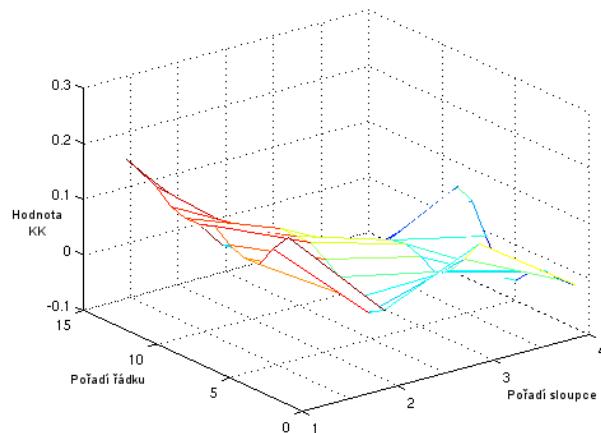
- Nejvyšší hodnota je patrná pro posun 12 pixel ve směru svislém (viz modrá šipka), což odpovídá předpokladu, že toto žíhání se projevuje spíše jako opakující se nesouvislý útvar.
- Nejnižší hodnota je patrná pro posun 12 pixel diagonálně (pod úhlem 45°).
- Parametr KV je pro sloupec s nejvyšší hodnotou o řád větší než v ostatních sloupcích. V porovnání s předchozím snímkem je jeho hodnota poloviční.
- Hodnoty PR a PR abs jsou největší pro různé směry.
- Obecně jsou nejvyšší hodnoty klasifikátorů více rozptýlené než tomu bylo u předchozího snímku.

6.2.3 Oblast bez pravidelné struktury

$R_U = 12$, $dR = 7$, hrana = 22 pixel



Obr. 6.5: Oblast bez pravidelné struktury



Obr. 6.6: Grafické zobrazení hodnot v tabulce KK

| R | Směr posunu | | | |
|----------------|---------------|--------|----------------|----------------|
| | ← | ↖ | ↑ | ↗ |
| 5 | 0,2024 | 0,0244 | 0,0961 | -0,0236 |
| 6 | 0,1695 | 0,0078 | 0,0574 | -0,0262 |
| 7 | 0,1289 | 0,0196 | 0,0248 | -0,0223 |
| 8 | 0,1278 | 0,0475 | 0,0100 | -0,0372 |
| 9 | 0,1405 | 0,0669 | 0,0263 | -0,0648 |
| 10 | 0,1629 | 0,0843 | 0,0352 | -0,0607 |
| 11 | 0,1523 | 0,0848 | 0,0298 | -0,0086 |
| 12 | 0,1521 | 0,0853 | -0,0015 | 0,0435 |
| 13 | 0,1600 | 0,0671 | -0,0296 | 0,0552 |
| 14 | 0,1847 | 0,0460 | -0,0482 | 0,0095 |
| 15 | 0,1987 | 0,0177 | -0,0624 | -0,0477 |
| 16 | 0,2080 | 0,0068 | -0,0781 | -0,0872 |
| Min | 0,1278 | 0,0068 | -0,0781 | -0,0872 |
| Max | 0,2080 | 0,0853 | 0,0961 | 0,0552 |
| PR | 0,0802 | 0,0785 | 0,1742 | 0,1424 |
| KV | 0,01668 | 0,0067 | 0,01675 | 0,0079 |
| ZV | 0,0102 | 0,0005 | -0,0136 | -0,0124 |
| Min abs | 0,1278 | 0,0068 | 0,0015 | 0,0086 |
| Max abs | 0,2080 | 0,0853 | 0,0961 | 0,0872 |
| PR abs | 0,0802 | 0,0785 | 0,0946 | 0,0787 |
| E | 1,6390 | 1,7651 | 1,7990 | 1,8213 |

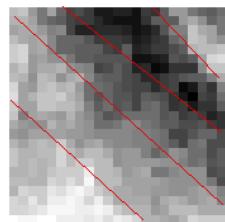
- Zde je zachycen výřez bez jakýchkoliv pravidelných struktur, rozložení odstínů šedé odpovídá náhodnému rozptylu.
- Nejvyšší hodnota je patrná pro posun 16 pixel ve vodorovném směru.
- Nejnižší hodnota je patrná pro posun 16 pixel v diagonálním směru (pod úhlem 135°).
- Ačkoliv nejčastěji byla dominantní hodnota klasifikačních parametrů vypočtena pro svislý posun, v kontextu rozptylu hodnot KK je zřejmé, že na tomto snímku se nenachází pravidelná struktura orientovaná vodorovně. Hodnoty KK jsou koncentrovány blízko nuly, což, jak bylo zmíněno v kapitole 4.3, značí malou míru vazby.

6.2.4 Výřez obsahující část cévy

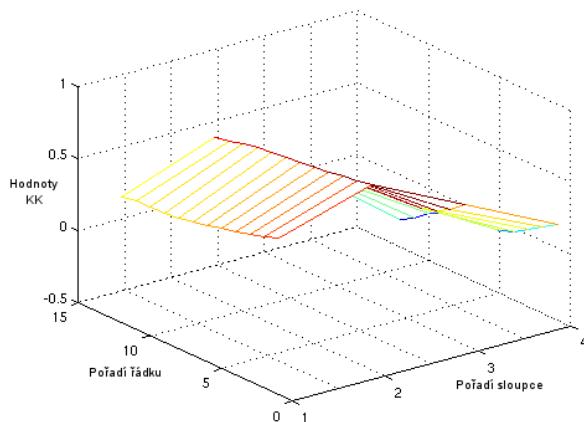
$R_U = 12$, $dR = 7$, hrana = 22 pixel



Obr. 6.7: Vstupní snímek



Obr. 6.8: Oblast s průběhem cévy



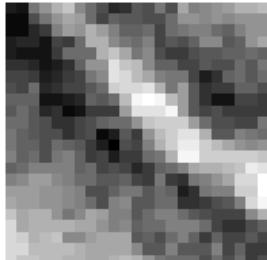
Obr. 6.9: Grafické zobrazení hodnot v tabulce KK

| R | Směr posunu | | | |
|----------------|-------------|---------------|---------------|----------------|
| | ← | ↖ | ↑ | ↗ |
| 5 | 0,5942 | 0,7861 | 0,4712 | 0,1548 |
| 6 | 0,5543 | 0,7701 | 0,3962 | 0,0919 |
| 7 | 0,5226 | 0,7539 | 0,3423 | 0,0360 |
| 8 | 0,4973 | 0,7338 | 0,3117 | -0,0315 |
| 9 | 0,4734 | 0,7221 | 0,2970 | -0,0696 |
| 10 | 0,4497 | 0,7126 | 0,2943 | -0,0812 |
| 11 | 0,4247 | 0,7020 | 0,2871 | -0,0891 |
| 12 | 0,4072 | 0,6915 | 0,2738 | -0,0970 |
| 13 | 0,3972 | 0,6790 | 0,2536 | -0,1281 |
| 14 | 0,3963 | 0,6632 | 0,2277 | -0,1757 |
| 15 | 0,3890 | 0,6344 | 0,2053 | -0,2544 |
| 16 | 0,3687 | 0,6131 | 0,1820 | -0,3097 |
| Min | 0,3687 | 0,6131 | 0,1820 | -0,3097 |
| Max | 0,5942 | 0,7861 | 0,4712 | 0,1548 |
| PR | 0,2255 | 0,1730 | 0,2892 | 0,4645 |
| KV | 0,1340 | 0,1360 | 0,1363 | 0,0719 |
| ZV | 0,0831 | 0,1061 | 0,0526 | -0,1439 |
| Min abs | 0,3687 | 0,6131 | 0,1820 | 0,0315 |
| Max abs | 0,5942 | 0,7861 | 0,4712 | 0,3097 |
| PR abs | 0,2255 | 0,1730 | 0,2892 | 0,2782 |
| E | 1,1998 | 0,7067 | 1,4605 | 1,8380 |

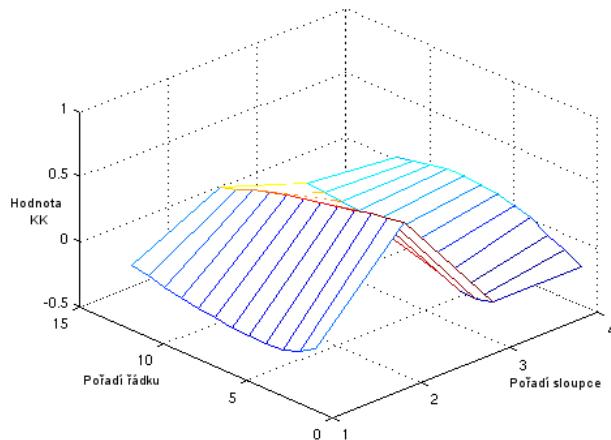
- Vybraná oblast obsahuje část cévy. Snímek je možné rozdělit na části s přibližně rovnoměrným rozložením odstínu šedé (jak ukazují červené linky). Tyto oblasti pak vykazují silnou míru provázanosti, pohybujeme-li se ve směru těchto linek (posun ve směru 45°). Pokud se pohybujeme ve směru kolmém na červené linky, není míra vnitřního uspořádání obdobně veliká s opačným znaménkem. To je určující pro vyhodnocení této oblasti jako oblasti bez žíhaní.
- Nejčastěji byla dominantní hodnota klasifikačních parametrů vypočtena pro diagonální posun (135°). V kontextu s velmi vysokou hodnotou KK pro směr 45° (pro zřetelně žíhanou oblast je KK = 0,44, pro jednolitou barvu je KK= 1) je zřejmé, že oblast obsahuje spíše jednolitou barevnou než žíhanou oblast.

6.2.5 Oblast obsahující část cévy i s jejím centrálním reflexem

$R_U = 12$, $dR = 7$, hrana = 22 pixel



Obr. 6.10: Oblast s cévou a centrálním reflexem



Obr. 6.11: Grafické zobrazení hodnot v tabulce KK

| R | Směr posunu | | | |
|----------------|--------------|--------------|---------------|--------|
| | ← | ↖ | ↑ | ↗ |
| 5 | -0,027 | 0,677 | -0,205 | -0,205 |
| 6 | -0,108 | 0,656 | -0,243 | -0,132 |
| 7 | -0,150 | 0,633 | -0,225 | -0,071 |
| 8 | -0,162 | 0,599 | -0,172 | 0,007 |
| 9 | -0,158 | 0,574 | -0,105 | 0,049 |
| 10 | -0,148 | 0,547 | -0,046 | 0,077 |
| 11 | -0,132 | 0,519 | -0,005 | 0,090 |
| 12 | -0,114 | 0,491 | 0,022 | 0,104 |
| 13 | -0,089 | 0,460 | 0,044 | 0,095 |
| 14 | -0,062 | 0,421 | 0,060 | 0,076 |
| 15 | -0,035 | 0,361 | 0,073 | 0,041 |
| 16 | -0,009 | 0,321 | 0,082 | 0,018 |
| Min | -0,162 | 0,321 | -0,243 | -0,205 |
| Max | -0,009 | 0,677 | 0,082 | 0,104 |
| PR | 0,153 | 0,356 | 0,325 | 0,308 |
| KV | -0,001 | 0,241 | 0,027 | 0,032 |
| ZV | -0,025 | 0,114 | -0,079 | -0,063 |
| Min abs | 0,009 | 0,321 | 0,005 | 0,007 |
| Max abs | 0,162 | 0,677 | 0,243 | 0,205 |
| PR abs | 0,153 | 0,356 | 0,238 | 0,197 |
| E | 1,868 | 1,073 | 1,829 | 1,784 |

- Nejvyšší hodnota odpovídá posunu o 5 pixel v diagonálním směru (45°). To přibližně odpovídá posunu po tmavém okraji cévy. Okolí cévy pak odpovídá šedo-tónovému rozložení obdobně jako v předchozím případě.
- Nejčastěji byla dominantní hodnota klasifikačních parametrů vypočtena pro sloupec s maximální hodnotou KK.
- Tato oblast se vyznačuje pravidelnou strukturou, kterou tvoří hrana cévy.
- Nejvyšší hodnota KK odpovídá nejmenší možné vzdálenosti posunu a od uživatelem zadané střední hodnoty se liší o velikost přípustné odchylky. Zmenšení přípustného intervalu odchylky však nepovede na zásadní zlepšení.
- Pravidelnost způsobená cévou a výrazná maximální hodnota KK může vést k chybnému vyhodnocení vybrané oblasti jako oblasti s pravidelnou strukturou ve formě žíhání.

6.3 Shrnutí

Funkčnost algoritmu ECOM byla ověřena na rozličných snímcích a bylo provedeno hodnocení klasifikačními parametry.

Oblast se žiháním se projevila zřetelně. Pro R jdoucí od 5 do 16 byl pozorován postupný přechod ze záporné do kladné a opět zpět do záporné hodnoty KK - pro liché násobky poloviny střední vzdálenost R_U byl KK záporný, pro sudé pak kladný. Zároveň se tato kladná hodnota KK projevila jako globálně nejvyšší v daném výřezu.

Oblast méně zřetelného žihání, jevíci se spíše jako pravidelně se opakující nesouvislé segmenty, se také výrazně projevila v tabulce KK.

Snímek bez pravidelné struktury nejevil výrazné známky provázanosti. Charakter náhodného rozložení intenzit ve snímku se projevil hodnotami KK koncentrovanými blízko nuly. Pro posun v horizontálním směru se hodnoty KK velmi málo odlišovaly, což je jasná známka malé texturní pravidelnosti.

Oblasti obsahující část cévy se projevovaly vysokými hodnotami KK, které byly způsobeny barevnou jednolitostí v dominantním směru. Tato céva vnáší do analyzovaného snímku prvek, který by mohl být chybně klasifikován jako žadoucí pravidelnost – žihání.

Pro klasifikaci dané oblasti jako oblasti s průběhem nervových drah je nutná kombinace více parametrů:

- Průběh hodnot KK pro jeden směr by měl odpovídat modelu - pro liché násobky poloviny střední vzdálenost R_U je KK záporný, pro sudé pak kladný.
- Dominantní hodnoty PR a KV se nacházejí ve stejném sloupci jako maximální hodnota.
- Hodnota maxima se nachází v jistém rozpětí tak, aby nebyly chybně diagnostikovány oblasti s jednolitou či náhodnou strukturou.
- Rozhodčí algoritmus musí brát v potaz kontext parametrů včetně hodnotám v tabulce KK. Například, je-li většina parametrů vyhodnocena jako dominantní pro jeden směr, nachází se v tomto směru i maximum? Je maximum přípustně velké/malé? Je rozptyl hodnot ve sloupci tabulky KK dynamický nebo spíše pozvolný? Mají hodnoty okolo maxima charakter harmonické funkce s přibližnou délkou čtvrtiny periody = $R_U / 2$ nebo se jedná o skokovou změnu hodnot či neharmonickou funkcí (tj. klesající / rostoucí / konstantní / slabě oscilující funkci přes celý přípustný obor hodnot R)?

- Parametr sloupcové entropie nevykázal signifikantní výsledky a proto nepovažuji jeho užití za nutné.

Algoritmus ECOM, užívající metodu hodnocení snímku na základě výpočtu korelačního koeficientu matice co-occurrence, je schopen odlišit oblast s průběhem nervových drah od oblasti bez těchto struktur. Dalším krokem před samotnou implementací do rozhodčího algoritmu je vytvoření statisticky významného souboru klasifikací a jejich srovnání se souborem hodnoceným zkušeným lékařem či osvědčenými algoritmy, které jsou v současné době vyvíjeny na ÚBMI.

7 Závěr

K diagnostice výpadků nervových drah na očním pozadí se kromě jiných metod užívá snímkování pomocí fundus kamery. K usnadnění a zpřesnění diagnostiky ošetřujícím lékařem je vhodné využívat autonomního diagnostického systému. V současné době je na ÚBMI takový systém vyvíjen. Tato práce si klade za cíl ověřit metodu analýzy oftalmologických snímků pomocí statistiky tzv. co-occurrenčních matic, potažmo klasifikaci těchto snímků pomocí korelačních koeficientů matic co-occurrence a parametrů z těchto koeficientů odvozených.

Tato práce se zabývala realizací programu pro výpočet co-occurrenčních matic z oblasti retinálního obrazu, v nichž je za normálních okolností textura odpovídající přítomnosti vrstvy nervových vláken. Naopak nepřítomnost textury indikuje onemocnění. Účelem programu bylo předně vytvořit a otestovat příslušné procedury, výsledně zahrnuté do experimentálního uživatelského programu, a následně ověřit chování matic pro reálné textury retinálních obrazů. Protože se ukázalo, že funkce, které jsou součástí „image-processing“ toolboxu MATLAB nesplňuje dostatečně obecně požadavky, byla procedura vytvořena nezávisle. Návazně pak byl program ověřován na výzezech reálných retinálních obrazů, přičemž byl kladen důraz na ověření funkčnosti metody analýzy pomocí statistiky co- occurrence a na schopnost vhodně interpretovat data z těchto matic získaná. Funkce ECOM proto byla vytvořena jako rychlý script pro splnění těchto požadavků. Jako hodnotící parametr se nejprve jevil výhodný výpočet míry vnitřního neuspořádání COM pomocí Haralickovy funkce – texturní entropie COM. Tato metoda však nedokázala jasně rozlišit oblasti bez výpadků a s výpadky nervových drah. Proto bylo od tohoto způsobu klasifikace upuštěno. Jako použitelná se ukázala klasifikace pomocí korelačních koeficientů COM. Z hodnot KK pak byly odvozeny přímo nebo vypočteny z odvozených hodnot klasifikační parametry.

Z důvodu nedostatku již dříve hodnocených snímků v požadované kvalitě nebyl vytvořen statistický soubor, z něhož by bylo možné sestavit soubor klasifikačních kritérií. Na základě rozboru charakteristických oblastí, resp. vzájemným porovnáním vypočtených klasifikačních parametrů, pak byla metoda ohodnocena jako funkční. Bylo zjištěno, že nelze brát v potaz pouze jeden klasifikační parametr, nýbrž je nutno použít více parametrů a to ideálně provázaných v kontextu s hodnotami v tabulce KK.

Funkce ECOM je programována jako script pro programové prostředí MATLAB a slouží k sestavení statistického souboru dat. Získáním jasných klasifikačních kritérií je možné rozšířit funkci ECOM o rozhodčí a třídící algoritmy nebo jej implementovat do komplexního diagnostického systému.

8 Použité zdroje

- [1] Ganong, W. F., „Přehled lékařské fyziologie“, Praha: H+H, 2002, str. 155 – 176,
ISBN 80-85787-36-9
- [2] Mornstein, V., Hrazdira, I., „Lékařská biofyzika a přístrojová technika“, Brno: Neptun,
2001. str. 180-191, ISBN 80-902896-1-4
- [3] Informační portál zabývající se komplexní problematikou glaukomu dostupný na WWW:
[<http://www.youreseyeguide.co.uk/glaucoma/index.html>](http://www.youreseyeguide.co.uk/glaucoma/index.html)
- [4] Informační portál pro pacienty trpící glaukomovým onemocněním dostupný na WWW:
[<http://www.glaukom.cz/kategorie.asp?idk=129>](http://www.glaukom.cz/kategorie.asp?idk=129)
- [5] CANON, přehled dostupných fundus kamer této značky dostupný na WWW:
[<www.usa.canon.com/html/industrial_medeq/ophthalmic_index.html>](http://www.usa.canon.com/html/industrial_medeq/ophthalmic_index.html)
- [6] Chen, C. H., Pau, L. F., Wang, P. S. P. (eds.) „The Handbook of Pattern Recognition and Computer Vision (2nd Edition)“, World Scientific Publishing Co., 1998., str. 207-248
- [7] Julesz, B., E. N. Gilbert, L. A. Shepp, and H. L. Frisch, “Inability of humans to discriminate between visual textures that agree in second-order statistics - revisited,” Perception, 1973. str. 391-405
- [8] Tesar, L., Smutek, D., Aiknobo S., Hidefume K., „Medical image segmentation using cooccurrence matrix based texture features calculated on weighted region.“, Proceedings of the 3rd IASTED conference, 2007, str. 243-248
- [9] Haralick, R. M. ,“Statistical and structural approaches to texture”, Proceedings of IEEE, vol. 67, no. 5, 1979, str. 786–804
- [10] Signal processing toolbox pro MATLAB, dokumentace online dostupná na WWW:
[<http://www.mathworks.com/access/helpdesk/help/toolbox/images/graycomatrix.html>](http://www.mathworks.com/access/helpdesk/help/toolbox/images/graycomatrix.html)

[11] Jähne, B., Haußecker, H., Geißler, P., „Handbook of Computer Vision vol. 2 Signal Processing and Pattern Recognition“, Academic Press, 1999, str. 279 - 282

9 Seznam použitých zkratek

| | |
|---------|---|
| A | Amakrinní buňky |
| BMP | Microsoft Windows Bitmap |
| C | Čípek |
| CO | Co-occurrence |
| COM | Co-occurrence matrix |
| DG | Difuzní gangliové buňky |
| dR | Povolená odchylka od R_U |
| E | Entropie sloupce tabulky KK |
| ECOM | Výpočetní script matic co-occurrence, korelačních koeficientů a klasifikačních parametrů. |
| FB | Ploché bipolární buňky |
| GCM | Graycomatrix |
| H | Horizontální buňky |
| ICG | Indigo – Cyan – Green |
| JPEG | Joint Photographic Experts Group |
| KK | Korelační koeficienty / korelačních koeficientů |
| KV | Váhování prostého rozdílu maximem ve sloupci |
| Max | Největší z hodnot ve sloupci tabulky KK |
| Max abs | Největší z absolutních hodnot ve sloupci tabulky KK |
| MB | Trpasličí bipolární buňky |
| MG | Trpasličí gangliové buňky |
| Min | Nejmenší z hodnot ve sloupci tabulky KK |
| Min abs | Nejmenší z absolutních hodnot ve sloupci tabulky KK |
| MPix | Mega – pixel (2^{20} obrazových bodů) |
| MRI | Magnetická rezonance |
| PET | Pozitronová emisní tomografie |
| PR | Prostý rozdíl maxima a minima z hodnot v tabulce KK |
| PR abs | Prostý rozdíl maxima a minima z absolutních hodnot v tabulce KK |
| R | Tyčinka |
| RB | Tyčinkové bipolární buňky |
| RGB | Red – Green – Blue |

| | |
|----------------|--|
| R _U | Uživatelem zadaná střední vzdálenost dvou nervových vláken |
| SR | Světločivné receptory |
| UBMI | Ústav biomedicínského inženýrství |
| ZV | Váhování prostého rozdílu minimem ve sloupci |

10 Seznam Příloh

Příloha 1: Zdrojový kód scriptu ECOM

1. Zdrojový kód scriptu ECOM

```

function ECOM(inputimage,position,hrana,offset,delta)

%Script ECOM vypocitava matici co-occurrence na zaklade uzivatelem
%pozadovaneho posunu o R pixelovych delek a odchylky od teto nominalni
%hodnoty pro 4 majoritni smery (0°,45°, 90° a 135°). Z techto matic je pak
%vypocitavana tabulka korelacnich koeficientu (TKK), z nichz jsou dale vypocitavany
%rozlicne klasifikaci parametry. Tento script neni automatizovany
%rozhodcim mechanismem.

%
%Format vstupnich parametru:
%inputimage = 'pozadovansnimek.pripona'
%position = [radek,sloupec], který bod vstupniho snimku je levym hornim rohem zajimaveho
vyberu
%hrana = numericka hodnota pozadovane velikosti vyberu z puvodniho snimku
%offset = pocet pixelovych delek uzivatelem pozadovaneho posunu
%delta = odchylka od offset, pocita se (offset-delta) az (offset+delta) s krokem 1
%
%Klasifikaci parametry:
%mini = minimalni hodnota ve sloupci TKK
%maxi = maximalni hodnota ve sloupci TKK
%rozdil = maxi-mini = realna vzdalenost hodnot ve sloupci TKK
%vahovani_pl = rozdil*maxi = do jaké míry je rozdíl způsoben maxi
%vahovani_mi = rozdil*mini = do jaké míry je rozdíl způsoben mini
%maxi_abs = maximalni hodnota ve sloupci tabulky absolutních hodnot KK
%maxi_abs = minimalni hodnota ve sloupci tabulky absolutních hodnot KK
%rozdil_abs = maxi_abs-mini_abs = vzdalenost absolutních hodnot ve sloupci TKK
%cor_table_avg_entr = entropie sloupce TKK

%% Prevod parametru zadanych volanim funkce
%V tomto bloku se prevadi zadane parametry do vhodneho formatu, dale se
%rozhoduje zda je snimek sedotonovy, pokud ne, je na sedotonovy preveden.
%Vybira se uzivatelem zadana zajimava oblast a vypocitava se matice moznych pixelovych
%delek.
%Vyhledavaji se take nejvyssi a nejznizsi hodoty sedotonovych intenzit v
%zajimave oblasti a jejim okoli. Vstupni snimek a zajimava oblast jsou
%nasledne zobrazeny. Blok dale obsahuje rozhodci mechanismus, který prerusi
%vypocet, pokud uzivatelem zadane vstupni hodnoty povedou na prekroceni
%hranic vstupniho snimku.

```

```

img = imread(inputimage);
svisle = position(1);
vodorovne = position(2);
vel = hrana;
ofst = offset;
dR = delta;

switch (size(img,3))
    case(1)
        sprintf('Nacteny snimek je sedotonovy')
    case(3)
        sprintf('Nacteny snimek je barevny, bude preveden do sedotonoveho')
        img = rgb2gray(img);
end

if ofst < dR
    error('Stredni hodnota je mensi nez povolena odchylka, nezle pouzit zapornou vzdalenost. Prosim zmente rozsah!')
else

A_T = svisle-ofst-dR;
A_B = svisle+vel;
A_L = vodorovne-ofst-dR;
A_R = vodorovne+ofst+vel+dR;
A_R2 = vodorovne+vel;

if A_T < 0 || A_B > size(img,1) || A_L < 0 || A_R > size(img,2) || A_R2 > size(img,2)
    error('Posun mimo rozsah vstupniho snimku. Prosim zmente rozsahy!')
else

A = img(svisle:svisle+vel, vodorovne:vodorovne+vel);
R = ((ofst-dR):1:(ofst+dR-1));

img_max = max(max(img((svisle-ofst-dR):(svisle+vel),(vodorovne-ofst-dR):(vodorovne+vel+ofst+dR)))); 
img_min = min(min(img((svisle-ofst-dR):(svisle+vel),(vodorovne-ofst-dR):(vodorovne+vel+ofst+dR)))); 
img_lev = (img_max-img_min)+1;

figure
subplot(1,2,1)
imshow(img,[])
subplot(1,2,2)
imshow(A,[])

```

%% Vypocet ofsetu

%Na zaklade uzivatelem zadane hodnoty poctu pixelovych delek a odchylky se
%vypocitavaji vektory posunu do jednotlivych majoritnich smeru. Tyto
%vektory jsou definovany polomerem a uhlem a tudiz pro diagonalni smery
%je nutno vypocitat skutecne posuny pomoc trigonometrickych funkci.

```
ofst = zeros((4*length(R)),2);
ofst_x = (-3);
for R_lev = 1:length(R)
    ofst_x = ofst_x+4;
    ofst(ofst_x,1) = 0;
    ofst(ofst_x,2) = (-R(R_lev));
    ofst(ofst_x+1,1) = (-ceil(R(R_lev)*sin(pi/4)));
    ofst(ofst_x+1,2) = (-ceil(R(R_lev)*cos(pi/4)));
    ofst(ofst_x+2,1) = (-R(R_lev));
    ofst(ofst_x+2,2) = 0;
    ofst(ofst_x+3,1) = (-ceil(R(R_lev)*sin(pi/4)));
    ofst(ofst_x+3,2) = (ceil(R(R_lev)*cos(pi/4)));
end
```

%% Vypocet COM

%V tomto bloku jsou vypocitavany matice Co-occurrence pro jednotlive
%offsety. Vypocet probiha srovnanim pixelovych hodnot v zajimave oblasti
%s pixely, ktere nemusi(ale mohou) do teto oblasti patrit(napriklad pixely
%pri hranach vyberu a k nim zajimave protejsky jiz za hranou vyberu).

```
maticecom = zeros(img_lev,img_lev,length(ofst));
for vrstva = 1:length(ofst)
    for svise=svisle:svisle+vel
        for vodo=vodorovne:vodorovne+vel
            k=img(svise,vodo);
            l=img(svise+ofst(vrstva,1),vodo+ofst(vrstva,2));
            maticecom((k-img_min+1),(l-img_min+1),vrstva)=maticecom((k-img_min+1),(l-img_min+1),vrstva)+1;
        end
    end
end
```

%% Normalizovani matice co-occurrence

```
maticecom = maticecom./(size(A,1)*size(A,2));
```

%% Vypocet korelacnich koeficientu

%Zde se nachazi vypocetni algoritmus pro kalkulace korelacnich koeficientu
%z co-occurrence matic. Jednotlive hodnoty pak jsou ukladany do tabulky
%korelacnich koeficientu, ze ktere jsou vypocitavany jednotlive
%klasifikaci parametry. TKK je automaticky formatovana tak, aby sloupce
%predstavovaly jednotlive smery posunu a radky pocet pixelovych delek.
%Parametry my_x, my_y, sigma_x a sigma_y jsou dulezite soucasti pro vlastni
%vypocet korelacnich koeficientu. Jejich smysl je vysvetlen v casti
%bakalarske prace tomuto tematu venovane.

```
COR = 0;
my_x = 0;
my_y = 0;
sigma_x = 0;
sigma_y = 0;

cor_table = zeros(length(R),4);
for COz = 1:size(maticecom,3)
    for sub_x = 1:size(maticecom,1)
        for sub_y = 1:size(maticecom,2)
            my_x = my_x+double((sub_x)*maticecom(sub_x,sub_y,COz));
            my_y = my_y+double((sub_y)*maticecom(sub_x,sub_y,COz));
        end
    end

    for sub2_x = 1:size(maticecom,1)
        for sub2_y = 1:size(maticecom,2)
            sigma_x = sigma_x+double(((sub2_x-my_x)^2)*maticecom(sub2_x,sub2_y,COz));
            sigma_y = sigma_y+double(((sub2_y-my_y)^2)*maticecom(sub2_x,sub2_y,COz));
        end
    end

    sigma_x = sqrt(sigma_x);
    sigma_y = sqrt(sigma_y);

    for COx = 1:size(maticecom,1)
        for COy = 1:size(maticecom,2)
            COR = COR+double(COx*COy*maticecom(COx,COy,COz));
        end
    end

    mod_ind = mod(COz,4);
    if mod_ind == 0
        cor_table(ceil(COz/4),4) = ((COR-(my_x*my_y))/(sigma_x*sigma_y));
    else
        cor_table(ceil(COz/4),mod_ind) = ((COR-(my_x*my_y))/(sigma_x*sigma_y));
    end
end
```

```

end

COR = 0;
sigma_x = 0;
sigma_y = 0;
my_x = 0;
my_y = 0;
end

<% Prumerovani korelacni tabulky a mesh zobrazeni prubehu
%Zde jsou prumerovany vzdy tri po sobe jdouci prvky ve sloupci. Tim se
%zajisti mensi "skoky" mezi temito prvky - dochazi k vyhlazeni prubehu.
%Takto upravena tabulka je nasledne zobrazena.

cor_table_avg = zeros(size(cor_table,1)-2,4);
for cor_lay=1:size(cor_table,1)-2;
    cor_table_avg(cor_lay,1) = (cor_table(cor_lay,1)+cor_table(cor_lay+1,1)+cor_table(cor_lay+2,1))/3;
    cor_table_avg(cor_lay,2) = (cor_table(cor_lay,2)+cor_table(cor_lay+1,2)+cor_table(cor_lay+2,2))/3;
    cor_table_avg(cor_lay,3) = (cor_table(cor_lay,3)+cor_table(cor_lay+1,3)+cor_table(cor_lay+2,3))/3;
    cor_table_avg(cor_lay,4) = (cor_table(cor_lay,4)+cor_table(cor_lay+1,4)+cor_table(cor_lay+2,4))/3;
end

figure
mesh(cor_table_avg);

<% Vypocty klasifikacich kriterii
%Zde se vypocitavaji jednotlive klasifikacni parametry z jiz prumerovane
%TKK. Kazdy parametr je ulozen do samostatneho textoveho souboru
%pro naslednou manipulaci a export napriklad do programoveho prostredi
%EXCEL. Kazdy parametr je take vyspan do dialogoveho okna programu Matlab.
%Statisticke zpracovani souboru techto hodnot by melo vest k vytvoreni
%automatickeho rozhodcickeho algoritmu.

mini = zeros(1,4);
mini(1,1) = min(cor_table_avg(:,1));
mini(1,2) = min(cor_table_avg(:,2));
mini(1,3) = min(cor_table_avg(:,3));
mini(1,4) = min(cor_table_avg(:,4));
save('minimum_ve_sloupci.txt','mini','-ASCII')

maxi = zeros(1,4);
maxi(1,1) = max(cor_table_avg(:,1));
maxi(1,2) = max(cor_table_avg(:,2));
maxi(1,3) = max(cor_table_avg(:,3));
maxi(1,4) = max(cor_table_avg(:,4));
save('maximum_ve_sloupci.txt','maxi','-ASCII')

```

```

rozdil = zeros(1,4);
rozdil(1,1) = maxi(1,1)-mini(1,1);
rozdil(1,2) = maxi(1,2)-mini(1,2);
rozdil(1,3) = maxi(1,3)-mini(1,3);
rozdil(1,4) = maxi(1,4)-mini(1,4);
save('rozdil.txt','rozdil','-ASCII')

vahovani_pl = zeros(1,4);
vahovani_pl(1,1) = rozdil(1,1)*maxi(1,1);
vahovani_pl(1,2) = rozdil(1,2)*maxi(1,2);
vahovani_pl(1,3) = rozdil(1,3)*maxi(1,3);
vahovani_pl(1,4) = rozdil(1,4)*maxi(1,4);
save('vahovani_maximem_ve_sloupci.txt','vahovani_pl','-ASCII')

vahovani_mi = zeros(1,4);
vahovani_mi(1,1) = rozdil(1,1)*mini(1,1);
vahovani_mi(1,2) = rozdil(1,2)*mini(1,2);
vahovani_mi(1,3) = rozdil(1,3)*mini(1,3);
vahovani_mi(1,4) = rozdil(1,4)*mini(1,4);
save('vahovani_minimem_ve_sloupci.txt','vahovani_mi','-ASCII')

cor_table_avg_abs = abs(cor_table_avg);

mini_abs = zeros(1,4);
mini_abs(1,1) = min(cor_table_avg_abs(:,1));
mini_abs(1,2) = min(cor_table_avg_abs(:,2));
mini_abs(1,3) = min(cor_table_avg_abs(:,3));
mini_abs(1,4) = min(cor_table_avg_abs(:,4));
save('minimum_abs.txt','mini_abs','-ASCII')

maxi_abs = zeros(1,4);
maxi_abs(1,1) = max(cor_table_avg_abs(:,1));
maxi_abs(1,2) = max(cor_table_avg_abs(:,2));
maxi_abs(1,3) = max(cor_table_avg_abs(:,3));
maxi_abs(1,4) = max(cor_table_avg_abs(:,4));
save('maximum_abs.txt','maxi_abs','-ASCII')

rozdil_abs = zeros(1,4);
rozdil_abs(1,1) = maxi_abs(1,1)-mini_abs(1,1);
rozdil_abs(1,2) = maxi_abs(1,2)-mini_abs(1,2);
rozdil_abs(1,3) = maxi_abs(1,3)-mini_abs(1,3);
rozdil_abs(1,4) = maxi_abs(1,4)-mini_abs(1,4);
save('rozdil_abs.txt','rozdil_abs','-ASCII')

cor_table_avg_shift = (cor_table_avg+1)/2;

```

```

cor_table_avg_entr = zeros(1,4);
for ctas_radky = 1:size(cor_table_avg_shift,1)
    if cor_table_avg_shift(ctas_radky,1) ~= 0
        cor_table_avg_entr(1,1) = cor_table_avg_entr(1,1)+...
(double(cor_table_avg_shift(ctas_radky,1)))*log10(double(cor_table_avg_shift(ctas_radky,1)));
    end

    if cor_table_avg_shift(ctas_radky,2) ~= 0
        cor_table_avg_entr(1,2) = cor_table_avg_entr(1,2)+...
(double(cor_table_avg_shift(ctas_radky,2)))*log10(double(cor_table_avg_shift(ctas_radky,2)));
    end

    if cor_table_avg_shift(ctas_radky,3) ~= 0
        cor_table_avg_entr(1,3) = cor_table_avg_entr(1,3)+...
(double(cor_table_avg_shift(ctas_radky,3)))*log10(double(cor_table_avg_shift(ctas_radky,3)));
    end

    if cor_table_avg_shift(ctas_radky,4) ~= 0
        cor_table_avg_entr(1,4) = cor_table_avg_entr(1,4)+...
(double(cor_table_avg_shift(ctas_radky,4)))*log10(double(cor_table_avg_shift(ctas_radky,4)));
    end
end

cor_table_avg_entr = -cor_table_avg_entr;
save('entropie_ve_sloupci.txt','cor_table_avg_entr','-ASCII')

```

%% Zobrazení jednotlivých parametrů

```

sprintf('Minimum = %5.4f \n',mini)
sprintf('Maximum = %5.4f \n',maxi)
sprintf('Prostý rozdíl = %5.4f \n',rozdíl)
sprintf('Vahování kladné = %5.4f \n',vahovani_pl)
sprintf('Vahování zaporné = %5.4f \n',vahovani_mi)
sprintf('Maximum z absolutních hodnot = %5.4f \n',maxi_abs)
sprintf('Minimum z absolutních hodnot = %5.4f \n',mini_abs)
sprintf('Rozdíl absolutních hodnot = %5.4f \n',rozdíl_abs)
sprintf('Entropie podle sloupcu = %5.4f \n',cor_table_avg_entr)

end
end

```