

ABSTRAKT

V tejto práci sa nachádza základný popis princípu optickej koherentnej tomografie, prehľad jej aplikácií a základné rozdelenie týchto systémov. Ďalej sa práca zaoberá charakterom obrazov optickej koherentnej tomografie, pre ktoré je typický šum zvaný spekle. V práci je uvedený princíp vzniku tohto šumu a využitie jeho závislosti na mikroštruktúre zobrazovaných tkanív pomocou textúrnej analýzy pre účely klasifikácie. Praktická časť tejto diplomovej práce pozostáva z prípravy fantómov, namerania testovacej sady dát na systéme OCT, implementovania metódy analýzy spekvov v MATLabe a otestovania funkčnosti implementovaných algoritmov na štandardnom texturálnom datasete a tiež na nameraných fantómových obrazových dátach. Metódy analýzy sú použité pre segmentáciu fantómových obrazových dát.

KLÚČOVÉ SLOVÁ

Optická koherentná tomografia, Spekle, Analýza spekvov, Textúrna analýza, Klasifikácia obrazov, Fantóm pre optickú koherentnú tomografiu, Segmentácia.

ABSTRACT

This paper presents basic principles of optical coherence tomography, review of applications and basic categorization of these systems. Paper also deals with the typical properties of images from optical coherence tomography, especially speckle pattern. This paper also provides an overview of the origin of speckle noise and utilization of its dependence on microstructure of probed tissue for image classification based on textural analysis. Experimental part of this paper consists of phantom preparation, data acquisition by OCT system, implementation of speckle analysis in MATLAB and of testing of its functionality on standard textural dataset and also on acquired image phantom data. Speckle analysis is used for phantom image data segmentation.

KEYWORDS

Optical coherence tomography, Speckle, Speckle analysis, Texture analysis, Image classification, Phantom for optical coherence tomography, Segmentation.

GALLO, V. *Analýza speklí pro segmentaci obrazů z optické koherentní tomografie*.
Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních
technologií, 2015. 59 s. Diplomová práce. Vedoucí práce: Ing. Petra Štohanzlová.

Prehlásenie

Prehlasujem, že svoju diplomovú prácu na tému „Analýza speklí pro segmentaci obrazů z optické koherentní tomografie“ som vypracoval samostatne pod vedením vedúcej 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 ďalej prehlasujem, že v súvislosti s vytvorením tejto diplomovej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúceho autorského zákona č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon) v znení neskorších predpisov, vrátane možných trestnoprávnych dôsledkov vyplývajúcich z ustanovení časti druhej, hlavy VI. díl 4 Trestního zákoníku č. 40/2009Sb.

PodĎakovanie

Ďakujem vedúcej diplomovej práce Ing. Petre Štohanzlovej za účinnú metodickú, pedagogickú a odbornú pomoc a ďalšie cenné rady pri spracovaní mojej diplomovej práce.

V Brne dňa

.....

(podpis autora)

Obsah

Zoznam obrázkov	viii
Zoznam tabuliek	ix
Úvod	1
1 Optická koherentná tomografia	2
1.1 Princíp	2
1.2 Základné rozdelenie systémov OCT.....	4
1.2.1 Time-domain OCT	4
1.2.2 Fourier domain OCT.....	5
1.3 Základné parametre systémov OCT.....	7
1.4 Charakter obrazu.....	8
1.4.1 Spekle	8
1.5 Aplikácie OCT.....	9
2 Metódy analýzy speklov	11
2.1 Textúrna analýza	11
2.1.1 Lokálne vlastnosti ako textúrne deskriptory.....	12
2.1.2 Co-occurence matice	13
2.1.3 Run-length matice	15
2.1.4 Autokorelačné funkcie	15
2.1.5 Parametrické modely textúr.....	16
2.1.6 Lokálny binárny vzor	17
3 Segmentácia	22
3.1 Segmentácia založená na hranovej detekcii.....	22
3.2 Regiónovo orientovaná segmentácia.....	22
3.2.1 Segmentácia delením a zlučovaním oblastí	23
4 Praktická časť	25

4.1 Fantómy	25
4.1.1 Postup prípravy gélov	25
4.2 Meranie a spracovanie dát.....	26
4.3 Implementované metódy klasifikácie.....	27
4.3.1 Co-occurrence matice a lokálne spektrálne parametre	27
4.3.2 Lokálne binárne vzory	28
4.4 Implementovaná metóda segmentácie.....	28
5 Testovanie metód	31
5.1 Dataset Brodatz	31
5.2 Fantómové dáta	31
5.3 Klasifikácia - co-occurrence matice a lokálne spektrálne parametre.....	32
5.4 Klasifikácia - Lokálne binárne vzory.....	34
5.5 Segmentácia - Lokálne binárne vzory.....	37
Záver	41
Literatúra	42
Zoznam príloh	44
A.1 Zdrojové texty	45
A.2 Funkcie	45
A.3 Dáta.....	46

Zoznam obrázkov

Obr. 1.1 Princíp Michelsonovho interferometru.....	2
Obr. 1.2 Pribeh intenzity signálu pri použití vysoko koherentného svetelného zdroja ..	3
Obr. 1.3 Pribeh intenzity signálu pri použití nízko koherentného svetelného zdroja	3
Obr. 1.4 Princíp OCT.....	4
Obr. 1.5 Vláknová verzia Time-domain systému OCT	5
Obr. 1.6 Vláknová verzia spectral domain systému OCT	6
Obr. 1.7 Vláknová verzia Swept source systému OCT	7
Obr. 2.1 Delenie lokálneho spektra pre získanie nízkeho počtu lokálnych spektrálnych parametrov: (zľava) klinový filter, kruhový filter, kombinovaný filter.....	13
Obr. 2.2 Model generovania textúry	16
Obr. 2.3 Identifikácia textúry založená na parametrickom modeli.....	17
Obr. 2.4 Princíp pôvodného lokálneho binárneho operátora.....	17
Obr. 2.5 Lokálne okolia rotované do ich minimálnej polohy – horný riadok a lokálne okolia, ktoré majú po rotácii rovnaký výsledný rotačne invariantný LBP kód	20
Obr. 3.1 Segmentácia delením a zlučovaním: (a) pôvodný obraz, (b) oblasti po delení, (c) výsledný obraz, (d) stromový graf deleného obrazu	24
Obr. 5.1 Deväť testovaných textúr Brodatz [22]	31
Obr. 5.2 Úspešnosť klasifikácie kombinácie operátorov $LBP_{8,1}$ a $C_{8,1}$	35
Obr. 5.3 Úspešnosť klasifikácie operátora $LBP_{8,1}$	36
Obr. 5.4 Umelo vytvorený obraz – kombinácia gélov č. 8 a č.11	38
Obr. 5.5 Výsledok prvej etapy segmentácie – hierarchické delenie, gély č. 8 a č. 13....	38
Obr. 5.6 Výsledok druhej fázy segmentácie – spájanie oblastí, gély č. 8 a č. 13.....	39
Obr. 5.7 Výsledok tretej fázy – klasifikácia pixelov, hranice segmentov, gély č. 8 a č. 13	39
Obr. 5.8 Výsledok tretej fázy – klasifikácia pixelov, segmenty, gély č. 8 a č. 13.....	39
Obr. 5.9 Výsledok segmentácie obrazu tvoreného z piatich textúr Brodatz.....	40

Zoznam tabuliek

Tab. 4.1 Prehľad zloženia pripravených gélov	26
Tab. 4.2 Parametre OCT systému Thorlabs OCS1300SS	27
Tab. 5.1 Matica zámen pre album Brodatz, veľkosť vzoriek 20×20	32
Tab. 5.2 Matica zámen pre $d = 3$, veľkosť okolia 30×30	33
Tab. 5.3 Matica zámen pre $d = 1$, veľkosť okolia 30×30	33
Tab. 5.4 Matice zámen $LBP_{8,1}$ a $C_{8,1}$, počet kvant. úrovní kontrastu: 4, veľkosť okolia: 24×24, hĺbka: a) 50, b) 250, c) 450	36
Tab. 5.5 Matica zámen $LBP_{8,1}$ a $C_{8,1}$, počet kvant. úrovní kontrastu: 4, veľkosť okolia: 24×24, hĺbka testovaných vzoriek: 250, hĺbka vzoriek pre vytvorenie tried: 50	37
Tab. 5.6 Matica zámen $LBP_{8,1}$ a $C_{8,1}$, počet kvant. úrovní kontrastu: 3, veľkosť okolia: 24×24, hĺbka testovaných vzoriek: 50, hĺbka vzoriek pre vytvorenie tried: 50	37

Úvod

Optická koherentná tomografia je zobrazovacia modalita, ktorá poskytuje obrázky priečného rezu tkanivom pomocou mapovania odrazivosti infračerveného svetla v blízkej oblasti. Optická koherentná tomografia štandardne dosahuje priestorové rozlíšenie 10 – 15 μm , a je preto vhodná pre zobrazovanie vrstiev a štruktúry tkanív. Má rozmanité aplikácie v oblasti medicíny a biológie rovnako ako v oblasti techniky. Hlavné uplatnenie má OCT v oftalmológii, kde je v dnešnej dobe považovaná za klinický štandard. Podobný rozvoj momentálne prebieha v kardiológii, kde prvé komerčné intravaskulárne systémy nachádzajú uplatnenie v klinickej praxi.

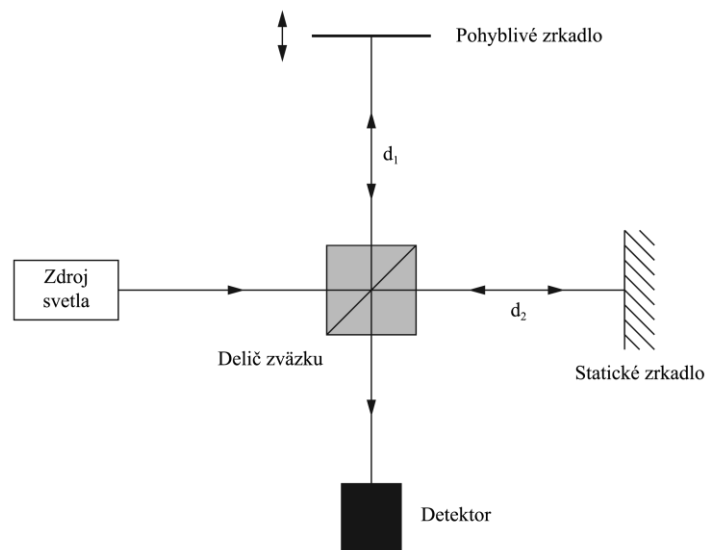
Možnosti ďalších aplikácií OCT, ako pomerne mladej zobrazovacej modality, sú predmetom výskumu. V OCT obrazoch kolagénu nie sú na prvý pohľad rozoznateľné žiadne štruktúry a môže sa zdať, že zobrazujú len exponenciálny útlm jasů s narastajúcou hĺbkou. Skúmanie týchto obrazov však ukazuje, že obsahujú štruktúry s opakujúcim sa charakterom vo forme speklů. Spekle sú charakteristickým šumom v obrazoch OCT a spôsobujú ich zrnitú štruktúru, ktorá rozmazáva detaily a zhoršuje kontrast obrazu. Informácia zakódovaná v štatistike ich intenzity a fázy, ktorá je závislá na mikroštruktúre zobrazovaného tkaniva, však môže byť využitá pre účely klasifikácie a segmentácie obrazu.

Táto práca je rozdelená na teoretickú a praktickú časť. V prvej časti sa nachádza základný popis princípu optickej koherentnej tomografie, prehľad jej aplikácií a základné rozdelenie týchto systémov. V práci je ďalej uvedený princíp vzniku speklů a prehľad metód textúrnej analýzy. V praktickej časti je uvedený popis prípravy fantómov, ktoré boli použité pre nameranie testovacej sady dát. Tieto dáta boli spolu so štandardným texturálnym datasetom použité pre overenie funkčnosti metód textúrnej analýzy založených na co-occurrence maticiach a lokálnych binárnych vzoroch. Následne boli metódy textúrnej analýzy použité pre segmentáciu fantómových obrazových dát. Všetky algoritmy boli implementované v programovom prostredí MATLAB.

1 Optická koherentná tomografia

1.1 Princíp


Optická koherentná tomografia (OCT) využíva interferenciu svetla a vychádza z princípu Michelsonovho interferometru. Základná schéma Michelsonovho interferometru je uvedená na obr. 1.1.



Obr. 1.1 Princíp Michelsonovho interferometru (upravené podľa [1])

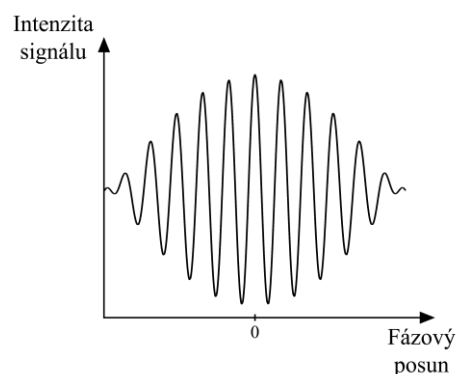
Svetlo vychádzajúce zo svetelného zdroja je na deliči zväzku – polopriepustnom zrkadle rozdelené na dva zväzky. Jeden zo zväzkov po odraze na deliči postupuje k pohyblivému zrkadlu. Druhý zväzok prechádza deličom a postupuje smerom k statickému zrkadlu. Zväzky sa po odraze na pohyblivom a statickom zrkadle vracajú pozdĺž smeru dopadu cez delič a dopadajú na fotodetektor. Dráhový rozdiel oboch vln pri dopade na fotodetektor je $\Delta d = 2(d_2 - d_1)$. Akákoľvek zmena tohto dráhového rozdielu spôsobí vzájomný fázový posun vln. Zmenou polohy pohyblivého zrkadla teda dochádza k fázovému posunu vln a intenzita svetla dopadajúceho na fotodetektor sa vplyvom interferencie mení. Ak je fázový rozdiel rovný nule, alebo násobku vlnovej dĺžky svetelného zdroja, dochádza pri skladaní vln ku konštruktívnej interferencii a intenzita signálu na fotodetektore je maximálna. Pri fázovom posune rovnom polovici vlnovej dĺžky svetelného zdroja alebo jej nepárnym násobkom dochádza ku deštruktívnej interferencii a intenzita signálu na fotodetektore je nulová. Fázový posun medzi týmito extrémami spôsobuje čiastočne deštruktívnu alebo čiastočne konštruktívnu interferenciu, kedy intenzita na fotodetektore nadobúda hodnoty medzi nulovou a maximálnou hodnotou v závislosti na veľkosti fázového posunu.

Priebeh intenzity svetla na fotodetektore pri použití vysoko koherentného svetelného zdroja, akým je napríklad laser, je uvedený na obr. 1.2. Michelsonovým interferometerom je teda možné merať rozmery objektov s presnosťou polovičnej vlnovej dĺžky svetelného zdroja.



Obr. 1.2 Priebeh intenzity signálu pri použití vysoko koherentného svetelného zdroja


Pri použití vysoko koherentného svetelného zdroja však nie je možné určiť, pri akej polohe zrkadla je dráhový rozdiel zväzkov nulový a z toho vyplýva, že pri tejto konfigurácii interferometra je možné stanoviť len relatívne posunutie. Túto nevýhodu je možné odstrániť použitím zložitejších usporiadaní interferometru, ktorých popis by bol nad rámec tejto práce. Ďalšou možnosťou je použitie nízko koherentného svetelného zdroja. Nízko koherentný zdroj je na rozdiel od laseru širokopásmový, so šírkou pásma rádovo desiatok až stoviek nanometrov. Ku konštruktívnej interferencii dochádza len pri nulovom fázovom posune všetkých vlnových dĺžok obsiahnutých vo svetle a ten je rovný nule len v prípade, že dĺžka optických dráh oboch zväzkov je rovnaká. Priebeh intenzity svetla na fotodetektore pri použití nízko koherentného svetelného zdroja je uvedený na obr. 1.3.



Obr. 1.3 Priebeh intenzity signálu pri použití nízko koherentného svetelného zdroja

Schéma z obr. 1.1 upravená nahradením statického zrkadla modelom tkaniva

transparentným pre vlnové dĺžky použitého svetelného zdroja je spolu s výstupným signálom detektoru uvedená na obr. 1.4. Model tkaniva obsahuje niekoľko čiastočne reflektívnych rozhraní. V prípade, že optická dráha d_1 medzi deličom zväzku a pohyblivým zrkadlom je rovnako dlhá ako optická dráha d_2 medzi čiastočne reflektívnym rozhraním tkaniva a deličom zväzku, dochádza na detektore ku konštruktívnej interferencii a veľkosť výstupného signálu detektoru je závislá na intenzite svetla, ktoré sa odrazilo od daného rozhrania, teda na jeho reflektivite. Posunom pohyblivého zrkadla vznikne jednorozmerný signál, kde nezávislou premennou je hĺbka a závislou premennou je odrazivosť tkaniva. [2], [3]



Obr. 1.4 Princíp OCT (upravené podľa [1])


1.2 Základné rozdelenie systémov OCT

Za posledných dvadsať rokov bolo navrhnutých množstvo technologických prístupov k realizácii OCT. Systémy OCT môžu využívať objemovú optiku, avšak flexibilita a veľká rozmanitosť vláknovej optiky uprednostňuje návrhy používajúce jednomódové optické vlákna.

1.2.1 Time-domain OCT

Prvá generácia systémov OCT, označovaná ako „time-domain“ OCT (TD OCT) je založená na princípe vyššie popísaného Michelsonovho interferometra. Klasické

usporiadanie vláknovej verzie systému tejto generácie je uvedené na obr. 1.5. Pozostáva zo svetelného zdroja, ktorým je v tomto prípade superluminiscenčná dióda (SLD), deliča zväzku vo forme 2×2 vláknovej odbočnice, pohyblivého zrkadla, detektoru a šošoviek L1 – L3, ktoré slúžia na fokusáciu zväzku.



Obr. 1.5 Vláknovia verzia Time-domain systému OCT (upravené podľa [4])

Jednorozmerný signál hĺbkového skenu je analogicky ku ultrasonografii označovaný ako A-sken. Vychyľovaním zväzku v smere kolmom na smer jeho šírenia a prevedením amplitúdovej modulácie signálu na moduláciu jasovú vzniká dvojrozmerný tomografický obraz tkaniva. Pre získanie objemových dát je zväzok vychyľovaný v dvoch na seba navzájom kolmých smeroch. Skenovanie môže byť zabezpečené pohybom snímanej vzorky, avšak pre urýchlenie procesu zobrazenia je uprednostňované vychyľovanie zväzku pomocou galvanometrických zrkadiel. [4]


1.2.2 Fourier domain OCT

Systémy označované ako „fourier domain OCT“ získavajú A-skeny pri nemennej dĺžke referenčného ramena interferometru meraním spektrálnej odozvy v podobe interferogramu vo frekvenčnej oblasti. Následnou Fourierovou transformáciou interferogramu je získaný hĺbkový profil reflektivity snímanej vzorky. Existujú dva základné prístupy k realizácii systémov fourier domain OCT, ktoré budú popísané v nasledujúcich podkapitolách.

1.2.2.1 Spectral domain OCT

Pre získanie interferogramu sa v systémoch spectral domain OCT (SD OCT) používa spektrometer. Usporiadanie vláknovej verzie uvedené na obr. 1.6 je podobné ako pri TD OCT systémoch s tým rozdielom, že referenčné rameno má konštantnú dĺžku


a výstupné rameno má na konci difrakčnú mriežku, ktorá rozkladá zväzok na jeho spektrum. Za difrakčnou mriežkou G je umiestnený detektor s detekčnými elementmi usporiadanými v jednej línii. Každý z detekčných elementov teda zaznamenáva intenzitu odrazeného svetla v rôznej časti spektra signálu.



Obr. 1.6 Vláknová verzia spectral domain systému OCT (upravené podľa [4])

1.2.2.2 Swept source OCT

Alternatívnym prístupom k SD OCT systémom je použitie preladiteľného úzkopásmového svetelného zdroja s dostatočným rozsahom vlnových dĺžok. Tieto systémy sa označujú ako swept source – teda s rozmiataným svetelným zdrojom. Zvyčajne sa jedná o laserovú diódu s pripojeným externým rezonátorom, ktorý pre selekciu vlnovej dĺžky využíva difrakčnú mriežku. V tomto prípade je spektrum signálu zaznamenané fotodetektorom postupne s meniacou sa vlnovou dĺžkou v celom rozsahu pásma. Usporiadanie systému tohto typu je uvedené na obr. 1.7. [4]



Obr. 1.7 Vlákňová verzia Swept source systému OCT (upravené podľa [4])

1.3 Základné parametre systémov OCT

Jedným z prvkov najvýraznejšie ovplyvňujúcich parametre systémov OCT je svetelný zdroj. Zdroj svetla OCT musí mať vlnovú dĺžku, ktorá zabezpečí dostatočný prienik zobrazovanou vzorkou. Biologické tkanivá majú relatívne nízky útlm pre vlnové dĺžky v rozsahu 700 až 1400 nm, kde spodnú hranicu určuje najmä odrazivosť a absorpcia pigmentov melanínu a hemoglobínu a hornú hranicu absorpcia vody. Kvôli menšej odrazivosti je pozorovaný väčší prienik pre vlnové dĺžky v okolí 1300 nm, zatiaľ čo vlnové dĺžky v okolí 800 nm poskytujú vyššie priestorové rozlíšenie. Jednou z osobitých vlastností OCT je, že hĺbkové rozlíšenie sa líši od laterálneho rozlíšenia. Pre dosiahnutie vysokého hĺbkového rozlíšenia musí byť koherenčná dĺžka svetelného zdroja čo najkratšia. Pre spektrum s gaussovským rozdelením so šírkou $\Delta\lambda$ (FWHM) a centrálnou vlnovou dĺžkou λ_0 je koherenčná dĺžka l_c daná rovnicou 1.1. [4]

$$l_c = \frac{2 \ln 2 \lambda_0^2}{\pi \Delta\lambda} \quad (1.1)$$

Veľká šírka spektra niektorých svetelných zdrojov v spojení so skutočnosťou, že rozlíšenie OCT v médiu s indexom lomu n je l_c/n , umožňuje rozlíšenie v tkanivách približne 1 μm . Hoci systémy, v ktorých sa používajú femtosekundové lasery dosahujú vyššie rozlíšenie, superluminiscenčné diódy (SLD) sú vhodnejšou voľbou vzhľadom na veľkosť, cenu a jednoduchosť prevádzky. Spektrálna šírka jednotlivých SLD, pohybujúca sa v rozmedzí 25 až 75 nm, umožňuje axiálne rozlíšenie výrazne pod 10 μm pri vlnových dĺžkach v oblasti 800 nm a približne 10 μm pri vlnových dĺžkach v oblasti 1300 nm.

Transverzálne rozlíšenie je dané numerickou apertúrou fokusujúcej optiky, teda

priemerom zväzku a ohniskovou vzdialenosťou.

Keďže je OCT založené na interferometrii, má veľkú senzitivitu, čo umožňuje detekciu veľmi malých signálov. Vhodnou definíciou senzitivity systémov OCT je pomer medzi reflektivitou dokonale odraďajúceho zrkadla ($R = 1$) a koeficientom najmenšieho odrazu vo vzorke R_{min} , pri ktorom $SNR = 1$ (pomer signálu k šumu). Senzitivita je teda daná vzťahom 1.2. [5]. Senzitivita systémov OCT dosahuje hodnoty viac ako 100 dB. Vďaka tomu je možné detegovať signál odrazený zo vzorky s veľkosťou 10^{-10} pôvodného signálu. [4]

$$S = 1/R_{min} \quad (1.2)$$

Časová rozlišovacia schopnosť systémov OCT je daná rýchlosťou akvizície A-skenov, a tým pádom je limitovaná rýchlosťou skenovania zmenou dĺžky referenčného ramena pri systémoch time-domain, rýchlosťou odozvy detektorov detekčnej matice pri spectral domain systémoch a rýchlosťou zmeny vlnovej dĺžky svetelného zdroja pri swept source systémoch. Vysoká rýchlosť akvizície je dôležitá pri zobrazovaní veľkých objemov, obzvlášť pri *in vivo* aplikáciách, kde pohyb častokrát nie je možné ovplyvniť. Vysoká časová rozlišovacia schopnosť umožňuje korektné zobrazovanie vývoja scény v čase. Časová rozlišovacia schopnosť Fourier domain OCT systémov je podstatne vyššia, pretože pri nich odpadá nutnosť mechanického skenovania pomocou zmeny dĺžky referenčného ramena. [6]

1.4 Charakter obrazu

Podobne ako obrazy ostatných zobrazovacích techník využívajúcich koherenciu, aj obrazy OCT obsahujú šum zvaný spekle (z angl. speckle = škvrna). Tento šum spôsobuje zrnitú alebo škvrnitú štruktúru, zhoršuje kontrast a sťažuje schopnosť rozlíšiť hranice medzi štruktúrami s vysokou odrazivosťou v tkanivách. [7], [8]

1.4.1 Spekle

Spekle vznikajú interferenciou vln s náhodnou fázou. Výsledná vlna je tvorená sumáciou veľkého množstva vln vznikajúcich odrazom na optických rozhraniach v zobrazovanom tkanive.

Rozlišujú sa dve zložky speklav: spekle, ktoré sú nositeľmi signálu a signál poškodzujúce spekle. Prvá zložka vzniká jednotlivými odrazmi dopadajúceho svetla na optických rozhraniach, zatiaľ čo druhá vzniká z dôvodu interferencie fotónov, ktoré boli niekoľkonásobne odrazené v smere a v protismere šírenia svetla. Tieto fotóny majú z dôvodu náhodnej hĺbkovej distribúcie optických rozhraní v tkanive a z dôvodu kolísajúceho indexu lomu v tkanive náhodnú fázou [9].

Šumová zložka spekllov má typicky veľkosť jedného pixelu, a teda je možné potlačiť ju priemerovaním. Spekle nesúce informáciu o štruktúre tkaniva majú zvyčajne väčšiu veľkosť [10]. Vo výslednom obraze sú spekle viditeľné ako zrnitá štruktúra, ktorá rozmazáva detaily v obraze, avšak informácia zakódovaná v štatistike jej intenzity a fázy môže byť využitá. Táto dualita spôsobuje dva rôzne prístupy ku prítomnosti spekllov. Prvý prístup sa zameriava na potlačenie spekllov, zatiaľ čo ten druhý využíva štatistiku ich štruktúry, ktorá je závislá na mikroštruktúre zobrazovaného tkaniva. [11]

Veľkosť spekllov sa mení v závislosti na veľkosti ohniska fokusujúcej optiky a koherenčnej dĺžky zdroja - je teda funkciou rozlíšenia OCT systému. [10]

1.5 Aplikácie OCT

Optická koherentná tomografia má rozmanité aplikácie v oblasti medicíny a biológie, rovnako ako v oblasti techniky. Hlavné uplatnenie má OCT v oftalmológii, kde je v dnešnej dobe považovaná za klinický štandard. Podobný rozvoj momentálne prebieha v kardiológii, kde prvé komerčné intravaskulárne systémy nachádzajú uplatnenie v klinickej praxi.

V oftalmológii sa OCT využíva na priame zobrazovanie štruktúr oka predného a zadného segmentu *in vivo* ako aj *in vitro*. OCT poskytuje obraz priečného rezu sietnice s rozlíšením porovnateľným pri zobrazovaní histologických preparátov svetelným mikroskopom a umožňuje vizualizáciu štruktúr sietnice, ktoré nie je možné zobrazit' inými technikami. V porovnaní s vyšetrením očného pozadia pomocou fluoresceínovej angiografie je OCT neinvazívna a oproti ultrasonografii nevyžaduje fyzický kontakt s okom, ktorý vyšetrenie výrazne znepríjemňuje. Ako už bolo spomenuté, OCT predstavuje klinický štandard pri viacerých ochoreniach sietnice a je stále častejšie používaná v diagnostike, monitorovaní a kontrole liečby vitreomakulárneho trakčného syndrómu a makulárnych dier, vekom podmienenej makulárnej degenerácie, glaukómu a diabetickej retinopatie.

V kardiológii je hlavnou klinickou aplikáciou intravaskulárnej (IV) OCT monitorovanie a kontrola perkutánnej koronárnej intervencie, obzvlášť kontrola umiestnenia a priľnutia implantovaných koronárnych stentov k cieve. Predmetom výskumu je vyšetovanie a klasifikácia nestabilných aterosklerotických plakov, ktoré významne zvyšujú riziko infarktu myokardu. IV OCT umožňuje oproti IV ultrasonografii vďaka väčšiemu priestorovému rozlíšeniu zobrazenie podstatne menších detailov, a tým zvýšiť spoľahlivosť klasifikácie.

V oblasti medicíny bol skúmaný potenciál množstva možných aplikácií v klinickom prostredí. OCT preukazuje sľubné výsledky v mnohých odvetviach diagnostiky rakoviny, obzvlášť v tých, kde by mohli nahradiť chirurgickú biopsiu alebo

inú invazívnu metódu. Vláknové usporiadanie umožňuje integrovanie systému OCT do množstva bežne používaných zariadení v medicíne a teda aj použitie v endoskopii pre vyšetrenie dutých orgánov, ako sú napríklad gastrointestinálny trakt, priedušky ale aj močový mechúr. Podobne subkutánne zobrazovacie ihly a sondy rozširujú možnosti aplikácie. Príkladom môže byť artroskopická OCT ako sľubný nástroj vo včasnej diagnostike osteoartrózy alebo patológií meniskov.

Okrem diagnostiky je OCT užitočné pre monitorovanie alebo navigovanie chirurgických zákrokov. Sľubnou aplikáciou v tejto oblasti je vyšetrenie lymfatických uzlín pri rakovine prsníka. Pretože je posúdenie malignity možné len pooperatívne pomocou histopatológie, je v súčasnosti častokrát odstránených viac lymfatických uzlín, ako je potrebné. Vyšetrením morfológie a optických vlastností pomocou OCT môže chirurg s predstihom rozlíšiť, ktoré uzliny sú v skutočnosti metastatické, a tým znížiť počet zbytočných resekcí.

Ďalšou z oblastí, v ktorej je použitie OCT významne rozšírené je vývojová biológia. Jednou z množstva aplikácií je napríklad výskum vývoja srdca na zvieratách, ktorý poskytuje zásadné poznatky o normálnom a abnormálnom vývine srdca u stavovcov, čím môže prispieť k odhaleniu príčin vzniku vrodených srdcových chýb u človeka. [1], [6]

2 Metódy analýzy spekllov

Štatistika štruktúry spekllov bola v rôznych vedeckých prácach využitá pre segmentáciu rôznych vrstiev tkanív viditeľných v tomografických obrazoch, alebo pre odlišenie nádorového a zdravého tkaniva [8]. Ako už bolo spomenuté, štruktúra spekllov je závislá na mikroštruktúre zobrazovaného tkaniva a má určitú charakteristickú štatistiku. V obrazovej analýze je táto vlastnosť obrazu jednou z charakteristík textúry. Pre popis a hodnotenie týchto štatistík je preto možné použiť textúrnu analýzu.

2.1 Textúrna analýza

Textúry sú bežné v prirodzených obrazoch, a preto sú veľmi dobre vnímané a rozpoznávané zrakom. Významne prispievajú k rozpoznávaniu hraníc a charakteru častí obrazu, typov povrchu, tvaru objektov a niekedy tiež ich priestorového usporiadania. Aj napriek tomu je však zložitú textúru definovať a presná formálna definícia neexistuje. Používajú sa preto rôzne nejasné slovné opisy. Textúra preto môže byť popísaná ako časť obrazu, v ktorej má kolísanie intenzity určité charakteristické vlastnosti, vnímané človekom alebo analyzujúcim algoritmom ako uniformné (jednotné). Uniformita môže zahŕňať dokonca aj pomalé zmeny vo vzhľade textúry, ako napríklad na zakrivenom povrchu z dôvodu rôznej perspektívy a osvetlenia.

Textúra môže byť približne pravidelná alebo dokonca viac alebo menej periodická (tzv. silná textúra), alebo môže byť pomerne stochastická (náhodná), s charakteristickou štatistikou, ale bez viditeľnej priestorovej pravidelnosti (tzv. slabá textúra). Textúra môže mať prevládajúcu smerovú orientáciu (napr. hrán alebo pozdĺžnych buniek) alebo naopak, môže byť izotropická; môže byť hrubá alebo jemná, môže pôsobiť ako drsná alebo hladká, zrnitá, bunková alebo amorfná atď. Z dôvodu takto veľkej rozmanitosti rôznych vlastností, z ktorých len niektoré môžu byť dôležité v určitej konkrétnej úlohe, bolo navrhnutých množstvo prístupov pre textúrnu analýzu.

Množstvo textúr je tvorených vzájomne podobnými malými objektmi, obvykle pozostávajúcimi z malej skupiny pixelov, takzvaných primitív. Textúry môžu obsahovať jeden alebo viac druhov primitív (napr. vláken, zrn, atď.) Veľkosť primitív potom určuje či je textúra vnímaná ako hladká alebo drsná. Usporiadanie týchto primitív môže byť náhodné (slabé textúry) alebo viac alebo menej pravidelné (silné textúry).

Je zrejmé, že textúrna analýza sa zaoberá určitou oblasťou obrazu alebo dokonca celým obrazom v prípade, ak popisuje uniformnú textúru (napr. v analýze tkanív alebo materiálov). V týchto prípadoch je pre čo najpresnejšiu klasifikáciu výhodné vybrať čo možno najväčšie oblasti. Pre účely segmentácie obrazu založenej na klasifikácii

lokálnej textúry je však vhodné voliť menšie oblasti. Výber veľkosti analyzovanej oblasti je potom kompromisom medzi priestorovým rozlíšením a presnosťou klasifikácie. V tomto zmysle poskytuje textúrna analýza určité lokálne vlastnosti, a tým vytvára typicky vektorové parametrické obrazy. V nasledujúcich podkapitolách bude popísaných niekoľko rôznych metód textúrnej analýzy. [12]

2.1.1 Lokálne vlastnosti ako textúrne deskriptory


Pre určité textúry môžu byť parametre lokálnych štatistík prvého rádu, ako napríklad lokálny aritmetický priemer alebo rozptyl, aj napriek tomu, že nezahŕňajú priestorové vzťahy v lokálnej oblasti dostatočne charakterizujúcimi. Avšak množstvo textúr, konkrétne silných textúr, je charakterizovaných dôležitými priestorovými vzťahmi medzi ich primitívami, a preto by mala textúrna analýza zahŕňať štatistiky vyššieho rádu, ktoré popisujú rozdelenie pravdepodobnosti pre dvojice alebo skupiny pixelov s určitým priestorovým usporiadaním. Pre popis lokálnych vlastností textúr je ďalej možné využiť hodnotenie vo frekvenčnej oblasti (spektrálne vlastnosti) alebo napr. hodnotenie lokálneho histogramu a podobne. [12]

2.1.1.1 Parametre vo frekvenčnej oblasti

Lokálne aplikovanie unitárnych transformácií môže taktiež poskytnúť významné informácie o lokálnom charaktere obrazu. Aplikovanie transformácie na malom lokálnom okolí neumožňuje dosiahnuť veľké spektrálne rozlíšenie, čo však pri popise lokálnych vlastností nie je potrebné. Spektrálne rozlíšenie je dané veľkosťou oblasti na ktorú je transformácia aplikovaná – čím je oblasť menšia, tým je menšie aj spektrálne rozlíšenie. Je zrejmé, že počítanie spektrálnych parametrov pre každý pixel ako centrum lokálneho okolia nie je vhodné, pretože výsledné parametre okolí, ktorých centrálné pixely sú príliš blízko pri sebe budú z dôvodu veľkého prekrytia oblastí skoro rovnaké. Hustota centrálnych pixelov by preto mala byť volená v závislosti na veľkosti lokálneho okolia. Rozumné prekrytie oblastí by malo byť niekde medzi 1/3 a 2/3 v každom smere.

Dvojrozmerná diskretná Fourierova transformácia (DFT) dokáže poskytnúť informácie o lokálnom charaktere obrazu vo frekvenčnej oblasti. Celkové lokálne spektrum má príliš veľké množstvo zložiek a preto sa často používajú určité odvodené parametre. Príkladom takéhoto parametru môže byť energia vybraného frekvenčného pásma – súčet druhých mocnín spektrálnych koeficientov v určitých oblastiach spektra (viď obr. 2.1). Kruhový filter oddeľuje rôzne rozsahy absolútnych frekvencií a teda môže poskytnúť informáciu o prevažujúcich priestorových frekvenciách. Podobne, klinový filter určuje celkovú energiu v jednotlivých smeroch alebo presnejšie v rozsahu smerov, a tým umožňuje vyhodnotenie hlavnej priestorovej orientácie lokálnych zmien

intenzity. Kombináciou týchto dvoch filtrov vzniká hrubá aproximácia spektra poskytujúca informáciu o rozložení absolútnych frekvencií v rôznych smeroch.



Obr. 2.1 Delenie lokálneho spektra pre získanie nízkeho počtu lokálnych spektrálnych parametrov: (zľava) klinový filter, kruhový filter, kombinovaný filter [12]

Ďalšou možnosťou je ešte väčšie „zdrúžovanie“ týchto frekvencií do menšieho počtu parametrov alebo dokonca jedného parametru. Napríklad, rozptyl energií súboru kruhových filtrov poskytuje informáciu o rozložení veľkosti detailov v obraze, zatiaľ čo rozptyl energií klinových filtrov popisuje mieru (an)izotropie. [12]

2.1.2 Co-occurrence matice

Co-occurrence matice, v preklade matice súčasného výskytu, vyhodnocujú početnosť opakujúcich sa kombinácií intenzity pixelov i, j pre páry pixelov, ktoré sú umiestnené v definovanej vzájomnej pozícii – vo vzdialenosti d v smere φ (alebo kartézskymi diferenciálmi $\Delta x, \Delta y$).

Nech existuje obraz s q úrovňami odtieňu sivej, okolie pixelu (x, y) a okolie rovnakého tvaru a veľkosti pixelu $(x + \Delta x, y + \Delta y)$. Tieto dve oblasti môžu byť považované za dva obrazy rovnakej veľkosti, pre ktoré je zostrojený združený histogram. Tento dvojrozmerný histogram, tvorený maticou veľkosti $q \times q$ sa nazýva co-occurrence matica pre parameter posunu $(\Delta x, \Delta y)$. Elementy matice potom nesú informáciu o počte konkrétnych kombinácií odtieňov sivej na zodpovedajúcich pixeloch bez ohľadu na to, kde sa kombinácie nachádzajú v obraze.

Textúra je popísaná sadou co-occurrence matíc pre zvolené hodnoty parametru posunu. Parametre sú obvykle vyjadrené v polárnej súradnej sústave ako absolútna vzdialenosť d a smer φ . Diskrétna reprezentácia obrazu evidentne umožňuje len diskrétny hodnoty obidvoch parametrov, väčšinou sa používajú len štyri smery líšiace sa o uhol 45° ($\varphi = 0^\circ, 45^\circ, 90^\circ, \text{ a } 135^\circ$), a podobne d je celočíselným násobkom vzorkovacej vzdialenosti (vertikálne a horizontálne), alebo $\sqrt{2}$ krát väčším v diagonálnom smere. Často sa berie do úvahy len osem susedných pixelov.

Bežne býva z každej co-occurrence matice odvodených šesť, prípadne viac parametrov v podobe normalizovaných histogramov obsahujúcich odhad podmienených

pravdepodobnostných funkcií $s_\varphi(i, j|d, \varphi)$. Každá $s_\varphi(i, j|d, \varphi)$ vyjadruje pravdepodobnosť výskytu pixelu s odtieňom sivej i vo vzdialenosti d od pixelu s odtieňom sivej j v smere φ .

Päť často používaných parametrov je daných rovnicami 2.1 až 2.5 [10],

$$Energia = \sum_{i=0}^{q-1} \sum_{j=0}^{q-1} [s_\varphi(i, j|d)]^2, \quad (2.1)$$

$$Entropia = \sum_{i=0}^{q-1} \sum_{j=0}^{q-1} s_\varphi(i, j|\Delta r) \log(s_\varphi(i, j|d)), \quad (2.2)$$

$$Korelačný\ koeficient = \frac{\sum_{i=0}^{q-1} \sum_{j=0}^{q-1} (i - \mu_x)(j - \mu_y) s_\varphi(i, j|d)}{\sigma_x \sigma_y}, \quad (2.3)$$

$$Lokálna\ homogenita = \sum_{i=0}^{q-1} \sum_{j=0}^{q-1} \frac{1}{1 + (i - j)^2} s_\varphi(i, j|d), \quad (2.4)$$

$$Kontrast = \sum_{i=0}^{q-1} \sum_{j=0}^{q-1} (i - j)^2 s_\varphi(i, j|d), \quad (2.5)$$

kde $s_\varphi(i, j|d)$ je element co-ocurrence matice na pozícii (i, j) pre vzdialenosť d , q je počet odtieňov sivej. Význam zvyšných použitých výrazov je uvedený v rovnicach 2.6 až 2.9 [10].

$$\mu_x = \sum_{i=0}^{q-1} i \sum_{j=0}^{q-1} s_\varphi(i, j|d), \quad (2.6)$$

$$\mu_y = \sum_{i=0}^{q-1} j \sum_{j=0}^{q-1} s_\varphi(i, j|d), \quad (2.7)$$

$$\sigma_x = \sum_{i=0}^{q-1} (i - \mu_x)^2 \sum_{j=0}^{q-1} s_\varphi(i, j|d), \quad (2.8)$$

$$\sigma_y = \sum_{i=0}^{q-1} (j - \mu_y)^2 \sum_{j=0}^{q-1} s_\varphi(i, j|d). \quad (2.9)$$

Tieto parametre predstavujú rôzne spôsoby vyjadrenia distribúcie odtieňov sivej pomocou jedného čísla. [10]

Týmto spôsobom môže byť odvodených množstvo parametrov pre každé analyzované okolie pixelu (x, y) , ktoré je možné považovať za prvky vektoru lokálnych vlastností v obraze. Vektory všetkých pozícií (x, y) teda tvoria „texturálny parametrický obraz“. Použitie co-occurrence matíc našlo uplatnenie pre klasifikáciu rôznych typov textúr v početných aplikáciách. [12]

2.1.3 Run-length matice

Run-length matice je možné preložiť ako matice dĺžky behov. Behy sú definované ako súvislé sekvencie pixelov s rovnakými odtieňmi sivej v určitom smere (obvykle v smeroch $\varphi = 0^\circ, 45^\circ, 90^\circ, \text{ a } 135^\circ$). Princíp Run-length matíc môže byť vysvetlený na dvojrozmernom histograme, ktorého rozmermi sú odtiene sivej a dĺžka behu, ktorý vyjadruje početnosť výskytu behov konkrétnych dĺžok pre konkrétne odtiene sivej. Matice sú vytvorené pre každý zo smerov. Z týchto matíc sú vypočítané vhodné popisné parametre, ako napríklad zdôraznenie krátkych behov, zdôraznenie dlhých behov, nerovnomernosť jasovej úrovne, nerovnomernosť dĺžky behov, rozdelenie početnosti behov atď. Tieto parametre vytvárajú príznakový vektor pre každý bod (x, y) analyzovaného obrazu. Je zrejmé že run-length matice umožňujú rozlišovanie medzi textúrami s krátkymi a dlhými primitívami a takisto umožňujú rozpoznanie prevládajúcej orientácie týchto primitív. [12]

2.1.4 Autokorelačné funkcie


Dôležitou charakteristikou množstva textúr je opakujúci sa charakter. Diskrétna lokálna autokorelačná funkcia daná rovnicou 2.10

$${}_{x,y}R_{ff}(m, n) = \sum_i \sum_k f_{i,k} f_{i-m,k-n}, \quad (2.10)$$

vypočítaná pre malé okolie bodu so súradnicami (x, y) môže teda tiež odhaliť priestorové vlastnosti analyzovanej textúry. V zásade určuje hrubosť textúry šírku hlavného laloku funkcie – čím je veľkosť primitív väčšia, tým je hlavný lalok širší. Okrem toho sa v priebehu autokorelačnej funkcie prejaví pravidelná textúra ako vrcholy a údolia. Informácia obsiahnutá v autokorelačnej funkcii je ekvivalentná výkonovému spektru odvodenému z rovnakej oblasti. Pre použitie ako deskriptoru textúry je však kompletná autokorelačná funkcia príliš veľká a ťažko interpretovateľná. Pre zníženie veľkosti vektoru lokálnych parametrov v obraze sa preto používajú rôzne integrujúce deskriptory odvodené z autokorelačnej funkcie. Príkladom týchto deskriptorov môže byť už spomenutá šírka hlavného laloku alebo stupeň a frekvencia periodicít. [12]

2.1.5 Parametrické modely textúr

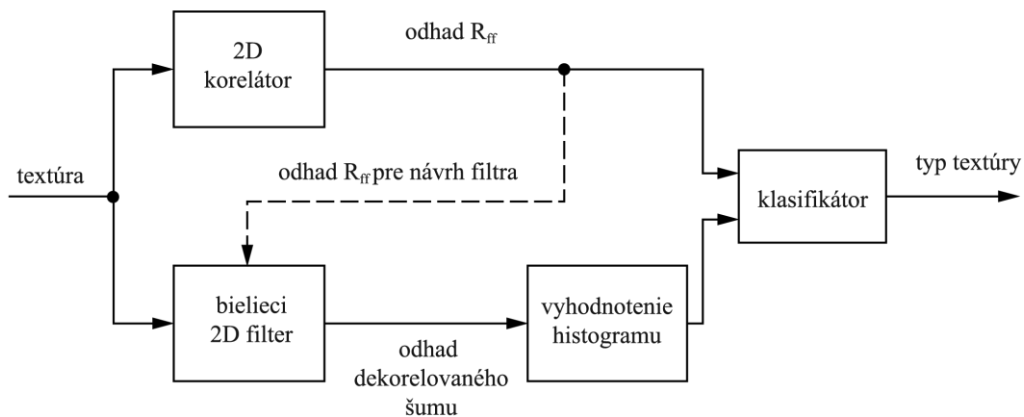
Rozdielny prístup k textúrnej analýze je založený na predstave modelovania vzniku textúry. Jednoduchá predstava modelu generovania textúry je znázornená na obr. 2.2.



Obr. 2.2 Model generovania textúry (upravené podľa [12])

Dvojrozmerný biely šum je vstupom lineárneho alebo nelineárneho systému (filtra), ktorý produkuje dvojrozmernú textúru. V závislosti na charaktere a parametroch filtra môžu byť získané rôzne textúry. Okrem vlastností filtra ovplyvňuje textúry aj pravdepodobnostné rozdelenie amplitúd vstupného šumu. Väčšinou sa predpokladá, že vstupný biely šum má Gaussovo rozdelenie a filter je lineárny. Často sú využívané autoregresívne modely, pretože v takom prípade je požadovaný inverzný filter odhadujúci parametre textúry iba nerekurzívny, čo znamená že má konečnú impulznú charakteristiku, tzv. FIR filter.

Metodológia popisu vlastností textúr pre lineárny model je založená na predstave bieliaceho filtra, ktorý je systémom konvertujúcim textúru na biely šum s rovnomerným spektrom. Bieliaci filter musí mať evidentne prenosovú funkciu inverznú ku prenosovej funkcii modelového filtra. Ako ukazuje teória signálov, bieliaci filter môže byť odvodený na základe autokorelačnej funkcie obrazu určovanej textúry. V momente, kedy je známy inverzný filter, jeho parametre, ktoré priamo súvisia s parametrami modelového filtra, môžu byť použité pre charakterizovanie textúry. Bieliaci filter navyše po aplikovaní na obraz textúry poskytuje odhad dekorelovaného vstupného šumu. Vďaka tomu je možné analyzovať pravdepodobnostné rozdelenie amplitúd šumu, ktoré tiež ovplyvňuje textúru prostredníctvom vytvorenia histogramu výstupu bieliaceho filtra, ako je znázornené na obr. 2.3. Týmto spôsobom je možné získať popis textúry pomocou parametrov založených na autokorelácii rovnako ako parametre odvodené z histogramu reštaurovaného šumu. Podobný prístup je založený na Markovových reťazcoch ako modeloch generujúcich textúry. Markovove reťazce sú dvojrozmerné náhodné procesy generujúce novú hodnotu pixelu s pravdepodobnostným rozdelením ovplyvneným niekoľkými vopred určenými hodnotami pixelov generovaného obrazu. Je možné ukázať, že pre Gaussovo rozdelenie je predošlý autorekurzívny model špeciálnym prípadom Markovovho modelu, z čoho vyplýva, že Markovove modely sú všeobecnejšie.

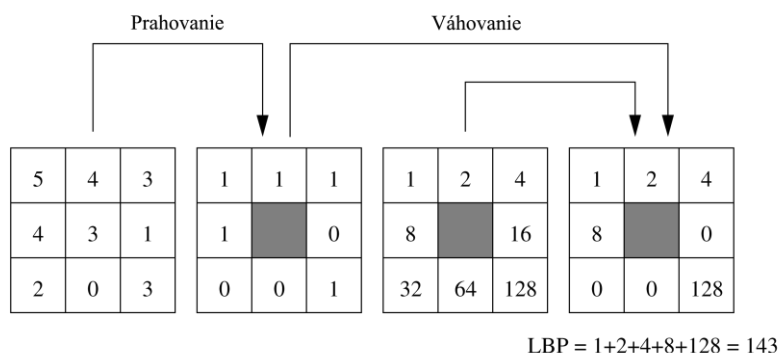


Obr. 2.3 Identifikácia textúry založená na parametrickom modeli (upravené podľa [12])

Podobne ako v predchádzajúcom prístupe môžu byť parametre Markovovho modelu použité ako parametre textúr pre ich klasifikáciu. Návrh modelu pre konkrétny typ textúry však nie je jednoduchý, pretože patričná štruktúra, rád modelu a pravdepodobnostné charakteristiky musia byť stanovené na základe určovanej textúry. [12]

2.1.6 Lokálny binárny vzor

Lokálny binárny vzor LBP (z angl. Local binary pattern) je operátor, ktorý popisuje textúru obrazu v lokálnom okolí centrálného pixelu. Okolité pixely sú prahované hodnotou tohto pixelu, následne váhované príslušnými váhami a ich hodnoty sčítané ako je uvedené na obr. 2.4 – pôvodná verzia LBP.



Obr. 2.4 Princíp pôvodného lokálneho binárneho operátora [13]

2.1.6.1 Odvodenie operátora LBP

Nech textúra T lokálneho okolia šedotónového obrazu je definovaná ako združená distribúcia odtieňov sivej $P + 1$ ($P > 0$) pixelov obrazu [14]:

$$T = t(g_c, g_0, \dots, g_{P-1}), \quad (2.11)$$

kde g_c je hodnota odtieňu sivej centrálného pixelu lokálneho okolia. Hodnoty $g_p (p = 0, \dots, P - 1)$ zodpovedajú hodnotám odtieňu sivej P pixelov rovnomerne rozložených na kružnici s polomerom $R (R > 0)$, ktoré tvoria rotačne symetrické okolie susedov. Súradnice susedov g_p sú určené ako [14]:

$$\left(x_c + R \cos\left(\frac{2\pi p}{P}\right), y_c - R \sin\left(\frac{2\pi p}{P}\right) \right), \quad (2.12)$$

kde (x_c, y_c) sú súradnice centrálného pixelu. Hodnoty susedov, ktorí neležia presne na pozíciách pixelov v obraze sú dopočítané bilineárnou interpoláciou.

Po odčítaní hodnoty centrálného pixelu od hodnôt susedov môže byť lokálna textúra vyjadrená (bez straty informácie) ako združená distribúcia hodnoty centrálného pixelu a diferencií [14]:

$$T = t(g_c, g_0 - g_c, g_1 - g_c, \dots, g_{P-1} - g_c). \quad (2.13)$$

Za predpokladu, že tieto diferencie nie sú závislé na hodnote g_c , môže byť distribúcia upravená do tvaru [14]:

$$T \approx t(g_c) t(g_0 - g_c, g_1 - g_c, \dots, g_{P-1} - g_c). \quad (2.14)$$

Keďže člen $t(g_c)$ vyjadruje len globálny jas obrazu, na ktorom lokálna textúra obrazu nie je závislá, neposkytuje pre analýzu textúry žiadnu relevantnú informáciu. Z toho dôvodu je väčšina informácie o charaktere textúry v pôvodnej distribúcii danej rovnicou 2.13 zachovaná v distribúcii diferencií [14]:

$$T \approx t(g_0 - g_c, g_1 - g_c, \dots, g_{P-1} - g_c). \quad (2.15)$$

Táto P rozmerná distribúcia diferencií zachytáva početnosť výskytu rôznych vzorov textúry v okolí každého z pixelov obrazu. Pre dosiahnutie invariantnosti voči akejkoľvek monotónnej transformácii stupnice odtieňov sivej sa berú do úvahy len znamienka diferencií [14]:

$$T \approx t(s(g_0 - g_c), s(g_1 - g_c), \dots, s(g_{P-1} - g_c)), \quad (2.16)$$

kde

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0. \end{cases} \quad (2.17)$$

Váhouvaním každého znamienka $s(g_p - g_c)$ binomickou váhou 2^p je distribúcia 2.16 transformovaná na unikátny LBP kód charakterizujúci lokálnu textúru obrazu v okolí (x_c, y_c) [14]:

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p. \quad (2.18)$$

V prípade $(P = 8, R = 1)$ vzniká operátor veľmi podobný pôvodnému LBP ktorý je uvedený na obr. 2.4. s tým rozdielom, že podľa 2.18 sú hodnoty susedov na diagonálach získané interpoláciou. [14]

2.1.6.2 Rotačne invariantný LBP

Výstupom operátora $LBP_{P,R}$ je 2^p rôznych hodnôt, ktoré zodpovedajú 2^p rôznym binárnym vzorom, ktoré môžu byť tvorené P pixelmi lokálneho okolia. Pri rotácii obrazu sa hodnoty odtieňov sivej g_p pohybujú po obvodě kruhu okolo g_c . Keďže je okolie vždy indexované proti smeru hodinových ručičiek od pozície v kladnom smere osi x , dôsledkom rotácie obrazu je prirodzene iná hodnota výstupu $LBP_{P,R}$. Je však zrejmé, že pre vzory pozostávajúce iba z núl alebo jednotiek toto neplatí. Pre odstránenie vplyvu rotácie musí byť každý LBP kód rotovaný späť do referenčnej pozície, čím sa dosiahne rovnaký výstup všetkých pootočených verzií binárneho kódu. Táto transformácia je vyjadrená takto [13]:

$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i) \mid i = 0, 1, \dots, P - 1\}, \quad (2.19)$$

kde index ri vyjadruje rotačnú invariantnosť operátora. Funkcia $ROR(x, i)$ cyklicky posúva P -bitové binárne číslo x i -krát do prava ($|i| < P$). A teda pre binárne číslo x dané [13]:


$$x = \sum_{k=0}^{P-1} 2^k a_k, \quad a_k \in \{0, 1\}, \quad (2.20)$$

je operácia ROR definovaná ako [13]:

$$ROR(x, i) = \begin{cases} \sum_{k=i}^{P-1} 2^{k-1} a_k + \sum_{k=0}^{i-1} 2^{P-i+k} a_k & i > 0 \\ x & i = 0 \\ ROR(x, P + i) & i < 0. \end{cases} \quad (2.21)$$

Rotačne invariantný kód vzniká rotáciou pôvodného kódu až do dosiahnutia jeho minimálnej hodnoty. Na obr. 2.5 je v hornom riadku uvedených šesť rotačne invariantných kódov. Pod nimi sú uvedené ich pootočené verzie ktoré majú vo výsledku rovnaký kód. Prvé dva kódy v hornom riadku sú rotačne invariantné samy o sebe

a preto neexistujú iné okolia produkujúce rovnaký kód. Tretí v poradí je výnimočný tým, že existujú práve dve jeho verzie. Každé zo zvyšných troch okolí má spolu sedem svojich pootočených verzií, z ktorých dve sú uvedené na obrázku. Spolu teda $LBP_{8,R}^{ri}$ môže nadobúdať 36 rôznych hodnôt – produkuje histogram tvorený 36 stĺpcami.



Obr. 2.5 Lokálne okolia rotované do ich minimálnej polohy – horný riadok a lokálne okolia, ktoré majú po rotácii rovnaký výsledný rotačne invariantný LBP kód [13]

Hrubá kvantizácia uhlového priestoru týmto operátorom je dosť neefektívna, pretože reálne obrazy sú málo kedy pootočené práve o 45° . Navyše, frekvencia výskytu jednotlivých vzorov sa dosť líši. S niektorými z nich sa možno stretnúť len zriedkavo, čo robí operátor štatisticky nestabilným.

2.1.6.3 Uniformný a rotačne invariantný uniformný LBP

Pre potlačenie negatívnych vlastností operátora $LBP_{P,R}^{ri}$ bol navrhnutý tzv. uniformný LBP operátor. Ten vznikol na základe zistenia, že určité vzory sú pre popis textúry zásadné a tvoria niekedy až 90% z celkového množstva vzorov textúry. Názov „uniformný“ vyjadruje jednu spoločnú črtu týchto vzorov: obsahujú najviac dva prechody 1-0 alebo 0-1 v rotačnom binárnom kóde. Matematická definícia uniformity U pre okolie G je daná takto [13]:

$$U(G_p) = |s(g_{p-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)|. \quad (2.22)$$

Za uniformné sú považované vzory s hodnotou U menšou, nanajvýš rovnou dvom. Celkový počet uniformných vzorov je $P(P - 1) + 2$. Rotáciou uniformných vzorov do polohy, v ktorej majú minimálnu hodnotu vzniká rotačne invariantný uniformný LBP operátor matematicky vyjadrený ako [13]:

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & U(G_p) \leq 2 \\ P + 1 & \text{inak.} \end{cases} \quad (2.23)$$

Problém hrubej kvantizácie po 45° je možné vyriešiť zvýšením počtu vzoriek P rotačného okolia, čím vzniká väčšie rozlíšenie s $360^\circ/P$ kvantizačnými krokmi.

2.1.6.4 Rozšírenia LBP

Vo všeobecnosti nie je textúra charakterizovaná len priestorovou štruktúrou ale aj intenzitou štruktúry, teda kontrastom. LBP operátor popisuje priestorovú štruktúru textúry v lokálnom okolí, ale tým, že neberie do úvahy veľkosť diferencií ignoruje kontrast, ktorý je ako už bolo naznačené významnou črtou textúry. Z tohto dôvodu je veľmi užitočné doplniť operátor LBP o operátor popisujúci mieru kontrastu.

Rotačne invariantný lokálny kontrast môže byť hodnotený množinou bodov rotačne symetrického okolia podobne ako LBP [14]:

$$VAR_{P,R} = \frac{1}{P} \sum_{p=0}^{P-1} (g_p - \mu)^2, \quad (2.24)$$

kde

$$\mu = \frac{1}{P} \sum_{p=0}^{P-1} g_p. \quad (2.25)$$

$VAR_{P,R}$ je podľa definície, rovnako ako LBP, invariantný voči posunu na stupnici odtieňov sivej a jedná sa vlastne o lokálny rozptyl.

Medzi druhý často používaný operátor kontrastu patrí $C_{P,R}$ [15]:

$$C_{P,R} = \frac{\sum_i^{n_1} g_i}{n_1} - \frac{\sum_j^{n_2} g_j}{n_2}, \quad (2.26)$$

kde

$$\begin{aligned} i &= n_1 \forall (g_c - g_{n_1}) \geq 0, \\ j &= n_2 \forall (g_c - g_{n_2}) < 0. \end{aligned} \quad (2.27)$$

Pre výsledný popis lokálneho okolia sa používa združená distribúcia LBP/C alebo LBP/VAR vo forme združených histogramov.

3 Segmentácia

Segmentácia obrazu je základným krokom v algoritme analýzy a spracovania obrazu. S rozvojom digitálnej techniky nachádza segmentácia široké uplatnenie. Príkladom môžu byť priemyselné aplikácie, bezpečnostné systémy, digitalizácia fyzických dokumentov, zobrazovacie systémy v medicíne, či digitálna fotografia.

Segmentácia delí obraz na časti - segmenty, ktoré zodpovedajú konkrétnym zmysluplným objektom alebo oblastiam v obraze. Vo výsledku má každý obrazový pixel priradený index vyjadrujúci jeho príslušnosť ku konkrétnemu segmentu. Získané segmenty by mali byť uniformné z hľadiska farby, intenzity alebo textúry. Je zrejmé, že príslušné oblasti by mali byť v zmysle týchto charakteristík odlišné.

Segmentačné algoritmy je možné rozdeliť na dve hlavné kategórie: riadené a neriadené. Pri neriadenej segmentácii sú druhy rôznych objektov alebo dokonca počet objektov neznáme. Pri riadenej segmentácii môžu algoritmy využiť predchádzajúcu vedomosť o počte alebo type objektov. Ďalšou možnosťou je rozdeliť algoritmy na regiónovo orientované a algoritmy založené na hranovej detekcii.

Väčšina operátorov analyzujúcich textúru poskytuje popis textúry obrazu pre jednotlivé pixely alebo malé oblasti obrazu. Regiónovo orientované metódy segmentácie obrazu zahŕňajú zoskupovanie príslušných oblastí s podobnými textúrnymi vlastnosťami. Úlohou metód založených na hranovej detekcii je hľadanie oblastí, kde sa vlastnosti textúry náhle menia. Existuje veľké množstvo rôznych algoritmov pre obidva prístupy.

3.1 Segmentácia založená na hranovej detekcii

Segmentácia založená na hranovej detekcii môže byť realizovaná rôznymi hranovými detektormi založenými na prvej alebo druhej derivácii. Pri použití prvej derivácie sa v odvodenom obraze hľadajú lokálne maximá ktoré prevyšujú stanovený prah. Pri detektoroch založených na druhej derivácii sa v odvodenom obraze hľadá prechod nulou.

3.2 Regiónovo orientovaná segmentácia

Segmentácia narastaním oblastí patrí medzi najznámejšie regiónovo orientované algoritmy. Je založená na umiestnení východzieho bodu – semienka do určitej oblasti a následným pripájaním okolitých pixelov pri splnení určitého kritéria homogenity.

Ďalšou skupinou sú algoritmy založené na zlučovaní elementárnych oblastí, ktoré je možné považovať za homogénne. Týmito oblasťami môžu byť jednotlivé pixely

alebo skupiny pixelov. Opäť sa overuje určité kritérium homogenity.

Ďalším známym regiónovo orientovaným algoritmom segmentácie je segmentácia algoritmom rozvodia.


3.2.1 Segmentácia delením a zlučovaním oblastí

Delenie oblastí je v určitom zmysle komplementárnym postupom k ich spájaniu. Základnou myšlienkou delenia je rozdeliť oblasti, ktoré nie sú z hľadiska vybraného kritéria jednotné (homogénne) na podoblasti. Postup je opakovaný so stále menšími regiónmi až kým každý z nich nie je homogénny. Samotné delenie však neposkytuje uspokojivú segmentáciu, pretože niektoré susediace regióny môžu zostať rozdelené aj napriek tomu, že spĺňajú kritérium pre zlúčenie. Z tohto dôvodu sa používa kombinácia obidvoch postupov. Je vhodné poznamenať, že výsledky segmentácie zlučovaním oblastí a výsledky segmentácie delením a zlučovaním oblastí sa môžu výrazne líšiť.

Najmenej komplikovaný spôsob delenia pozostáva z rozštvrtenia obrazu, ktoré je opakované na toľkých úrovniach, koľko je potrebné pre dosiahnutie homogenity vo vnútri regiónov. Stupeň homogenity je vyhodnotený v každej úrovni. Ak je nedostatočný, región je rozdelený na štvrtiny a tým vytvára novú úroveň. Oblasť po splnení kritéria homogenity prirodzene nepodlieha ďalšiemu deleniu. Týmto spôsobom je dosiahnutá hierarchická reprezentácia obrazu štvorstromom (quadtree) – obraz môže byť popísaný stromovým grafom. Najvyšší uzol (koreň) zodpovedá celému obrazu, uzol bezprostredne nižšej úrovne jeho štvrtinovým oblastiam, atď. Každý uzol teda reprezentuje časť obrazu, ktorého veľkosť a pozícia vyplývajú z pozície uzlu v grafe. Uzol je označený priemernou hodnotou parametru v oblasti, ktorú reprezentuje. Z tohto materského uzlu vedú v prípade nesplnenia kritéria homogenity ďalšie štyri vetvy do ďalšej dcérskej úrovne.

Po skončení procesu delenia by mal byť jeho výstup z dôvodov spomenutých na začiatku tejto podkapitoly podrobený algoritmu zlučovania oblastí.

Delenie oblastí teda poskytuje súbor vhodných počiatočných oblastí pre algoritmus zlučovania. Segmentácia delením a zlučovaním oblastí je pomerne robustná, hoci má prirodzene tendenciu k vytváraniu „schodovitých“ oblastí. Príklad výsledku tejto metódy segmentácie je spolu so zodpovedajúcim stromovým grafom uvedený na obr. 3.1. [12], [16]



Obr. 3.1 Segmentácia delením a zlučováním: (a) pôvodný obraz, (b) oblasti po delení, (c) výsledný obraz, (d) stromový graf deleného obrazu [12]

4 Praktická časť

Praktická časť tejto diplomovej práce pozostáva z prípravy fantómov, namerania testovacej sady dát na systéme OCT a implementovania metód analýzy speklôv a ich použitia pre segmentáciu obrazov z OCT. Všetky algoritmy boli realizované v programovom prostredí MATLAB.

4.1 Fantómy

Pre vhodné vlastnosti a dobrú dostupnosť bol ako materiál na prípravu fantómov zvolený agarózový gél. Rozdielne optické vlastnosti boli modelované:

- a) rôznymi koncentraciami agarózy,
- b) pridaním rôzneho množstva intralipidu do 1% agarózového gélu.

Agarózový gél je bežne využívaný pri gélovej elektroforéze. Agaróza vytvára termoreverzibilné gély pozostávajúce zo sietí reťazcov agarózy vzájomne pospájaných vodíkovými väzbami a veľkých pórov, ktoré zadržiavajú vodu. Koncentrácia agarózy ovplyvňuje veľkosť pórov vo vnútri gélu. So vzrastajúcou koncentraciou sa veľkosť pórov znižuje. Veľkosť pórov sa pohybuje v rozmedzí 0,1 až 1 μm v závislosti na druhu agarózy, koncentrácii a teplote okolitého prostredia [17]. Je možné predpokladať, že rôzna koncentrácia bude mať vplyv na charakter speklôv v obraze OCT.

Gél bol pripravený štandardným postupom, ktorý je uvedený napr. v návode na použitie DNA Electrophoresis Kitu [18] s tým rozdielom, že nebol použitý pufor, ktorý pri elektroforéze plní funkciu elektrolytu a pre prípravu fantómov nie je potrebný.

Intralipid je infúzna intravenózna emulzia, ktorá obsahuje kvapôčky tuku. Stanovenie veľkosti kvapôčiek je pri daných rozmeroch problematické a rôzne zdroje uvádzajú rôzne veľkosti. Podľa najnovšieho výskumu obsahuje intralipid kvapôčky s priemernou veľkosťou 0,3 μm [19]. Vlastnosti intralipidu od rôznych výrobcov sa však môžu líšiť. Je možné predpokladať, že rôzna koncentrácia intralipidu – rôzne množstvo rozptyľujúcich častíc má vplyv na koeficient rozptylu a teda na charakter speklôv.

4.1.1 Postup prípravy gélov

1. Práškovú agarózu rozpustíte v destilovanej vode.
2. Príslušné množstvo agarózy v destilovanej vode varte v hrubostennej sklenenej nádobe v mikrovlnnej rúre až do úplnej homogenizácie obsahu – pri miešaní sa tavenina javí číra.

3. Zmes nechajte vychladnúť cca 5 minút pri izbovej teplote, a potom ju nalejte do formy.

Pri prírave gélov s intralipidom bol intralipid primiešaný do gélu po jeho homogenizácii.

V tab. 4.1 sú uvedené koncentrácie pripravených gélov. Gély boli naliate do Petriho misiek s priemerom približne 2,5 cm do výšky približne 1 cm, z ktorých boli po vytuhnutí vybraté. Následne na nich boli namerané fantómové dáta.

Tab. 4.1 Prehľad zloženia pripravených gélov

Gél č.	Koncentrácia gélu [%]	Koncentrácia intralipidu [%]
1	0,5	0,0
2	1,0	0,0
3	1,5	0,0
4	2,0	0,0
5	2,5	0,0
6	3,0	0,0
7	3,5	0,0
8	1,0	0,25
9	1,0	0,125
10	1,0	0,0625
11	1,0	0,03125
12	1,0	0,015625
13	1,0	0,0078125
14	1,0	1,953125.10 ⁻³

4.2 Meranie a spracovanie dát

Dáta boli namerané na komerčnom systéme Thorlabs OCS1300SS. Podrobné parametre tohto systému sú uvedené v Tab. 4.2. Surové dáta zo systému boli uložené a následne spracované v programovom prostredí MATLAB. Binárny súbor obsahuje okrem surových dát i záhlavia, v ktorých sú uložené informácie o nastavení systému a vlastnostiach akvizície dát. Dáta vo forme frekvenčných spektier signálu zaznamenaných fotodetektorom boli pomocou spätnej Fourierovej transformácie prevedené na šedotónový obraz reprezentujúci intenzitu odrazov.

Pre kvantizáciu dát na 8-bitový šedotónový obraz výrobcu použitého systému OCT uvádza vzťah 4.1:

$$B = \log\left(\frac{A}{\max(A)}\right) a + b, \quad (4.1)$$

kde A je vstupný a B výstupný obraz, a a b sú konštanty zvolené podľa požadovaného kontrastu, jasú a rozsahu v dB. Nastavenie kontrastu a jasú slúži hlavne pre účely vizualizácie. Pre analýzu spekvov je však vhodnejšie pracovať so surovými dátami

bez akejkoľvek straty informácie. Z tohto dôvodu boli algoritmy testované na dátach surových a tiež zlogaritmovaných. Logaritmus bol použitý pre kompresiu dynamiky dát.

Tab. 4.2 Parametre OCT systému Thorlabs OCS1300SS

Optické vlastnosti	
Centrálne vlnová dĺžka	1325 nm
Šírka spektra (FWHM)	>100 nm
Koherenčná dĺžka	6,0 mm
Priemerný výstupný výkon	10 mW
Senzitivita	100 dB
Axiálna rýchlosť skenovania	16 kHz
Vlastnosti 2D zobrazenia priečného rezu	
Snímková frekvencia (512 riadkov na snímok)	25 fps
Maximálna zobrazovaná veľkosť	4000 × 512 px.
Maximálna zobrazovaná hĺbka	3,0 mm
Maximálna zobrazovaná šírka	10 mm
Transverzálne rozlíšenie	25 μ m
Axiálne rozlíšenie (vzduch/ voda)	12/9 μ m
Vlastnosti 3D zobrazenia	
Maximálna veľkosť zobrazovaného objemu (d, š, h)	10 × 10 × 3 mm
Maximálne rozlíšenie (d, š, h)	1024 × 1024 × 512 vx.
Čas skenovania objemu	cca 30 s

4.3 Implementované metódy klasifikácie

Pre analýzu speklôv boli implementované dve metódy. V prvej sú použité parametre odvodené z co-occurrence matíc, ktoré boli popísané v kapitole 2.1.2 kombinované s parametrami odvodenými vo frekvenčnej oblasti, ktorých princíp bol popísaný v kapitole 2.1.1. Druhá metóda je založená na popise textúry speklôv pomocou lokálnych binárnych vzorov a kontrastu, ktorých princíp bol popísaný v kapitole 2.1.6.

4.3.1 Co-occurrence matice a lokálne spektrálne parametre

Zo vstupných dát boli vybrané výrezy, z ktorých boli následne vypočítané co-occurrence matice pre štyri smery ($\varphi = 0^\circ, 45^\circ, 90^\circ, \text{ a } 135^\circ$). Pre každú z týchto štyroch matíc bolo vypočítaných päť parametrov: energia, entropia, korelačný koeficient, lokálna homogenita a kontrast. Ďalšie štyri parametre boli odvodené z výkonových spektier výrezov. Každý z parametrov popisuje energiu v jednom zo štyroch pásem spektra, čo vo výsledku dáva dvadsaťštyri príznakov pre každý výrez vo forme príznakového vektoru. Dĺžka vektoru určuje počet rozmerov parametrického priestoru. Voľbou dostatočného množstva výrezov bola vytvorená databáza tried. Samotná klasifikácia bola realizovaná výpočtom vzdialenosti vektoru príznakov vybraného výrezu v m -

rozmernom priestore (v prípade dvadsiatich štyroch príznačov $m = 24$) od vektorov jednotlivých tried databázy. Najnižšia vzdialenosť potom určovala príslušnosť testovaného vektoru do konkrétnej triedy. Pre vyhodnotenie vzdialenosti bola použitá Mahalanobisova vzdialenosť daná vzťahom 4.2 [20]:

$$d_{Mahalanobis} = \sqrt{(x_v - x_m)^T C^{-1} (x_v - x_m)}, \quad (4.2)$$

kde x_v je vektor parametrov vzorky textúry, x_m je vektor parametrov modelu textúry a C je kovariančná matica a klasifikátor k-najbližších susedov k-NN (z angl. k-Nearest Neighbors).

4.3.2 Lokálne binárne vzory

Podobne ako pri predchádzajúcej metóde boli z nameraných dát vybrané výrezy, pre ktoré boli vypočítané LBP a kontrast. Z odvodených parametrických obrazov bol vypočítaný histogram LBP a združený histogram LBP/C. Histogramy charakterizujúce konkrétnu triedu boli získané spriemerovaním histogramov výrezov z rovnakej triedy. Pre klasifikáciu bol použitý G-test (tiež log likelihood ratio test), test dobrej zhody, ktorý porovnáva rozdelenie histogramov ako pravdepodobnostných funkcií. Jedná sa o neparametrický test, a teda nevyžaduje znalosť rozdelenia pravdepodobnosti. Hodnota G-vzdialenosti vyjadruje pravdepodobnosť, že rozdelenia dvoch porovnávaných histogramov pochádzajú z tej istej populácie: čím je jej hodnota vyššia, tým je pravdepodobnosť, že vzorky pochádzajú z rovnakej populácie nižšia. Test je daný vzťahom 4.3 [21]:

$$G = 2 \left(\left[\sum_{v,m} \sum_{i=1}^n f_i \ln f_i \right] - \left[\sum_{v,m} \left(\sum_{i=1}^n f_i \right) \ln \left(\sum_{i=1}^n f_i \right) \right] \right. \\ \left. - \left[\sum_{i=1}^n \left(\sum_{v,m} f_i \right) \ln \left(\sum_{v,m} f_i \right) \right] \right. \\ \left. + \left[\left(\sum_{v,m} \sum_{i=1}^n f_i \right) \ln \left(\sum_{v,m} \sum_{i=1}^n f_i \right) \right] \right), \quad (4.3)$$

kde f_i je početnosť v stĺpci histogramu i , v je histogram vzorky textúry, m je histogram modelu textúry a n je počet stĺpcov histogramu.

4.4 Implementovaná metóda segmentácie

Realizovaný algoritmus využíva k popisu textúry združený histogram LBP/C a bol inšpirovaný algoritmom Ojala a Pietikäinen [15]. Pozostáva z troch etáp: hierarchického delenia oblastí, spájania oblastí a klasifikácie jednotlivých pixelov.

Na začiatku prvej etapy je obraz rozdelený na štvorce vopred zvolenej veľkosti S_{max} . Následne sa vyhodnocuje uniformita textúry v týchto štvorcoch. Ak štvorec nespĺní kritérium uniformity dané G-vzdialenosťami LBP/C histogramov zo šiestich kombinácií štyroch podoblastí, je rozdelený na štvrtiny. Kritérium je dané vzťahom 4.4, kde G_{max} je najväčšou a G_{min} najmenšou G-vzdialenosťou a X zvolený prah.

$$\frac{G_{max}}{G_{min}} > X \quad (4.4)$$

Proces sa opakuje až do dosiahnutia zvolenej minimálnej veľkosti oblastí S_{min} , ktorá obsahuje ešte dostatočný počet pixelov pre spoľahlivú charakterizáciu textúry.

V ďalšej etape nasleduje spájanie susedných oblastí s rovnakou textúrou. V jednotlivých krokoch sa spájajú páry susedných oblastí, ktoré spôsobia minimálnu zmenu v segmentovanom obraze. Veľkosť tejto zmeny Z je daná vzťahom 4.5

$$Z = p \times G, \quad (4.5)$$

kde p je počet pixelov menšej z dvoch zlučovaných oblastí a G je vzdialenosť daná vzťahom 4.3. Vždy po spojení je vypočítaný histogram LBP/C vznikutej oblasti a jej G-vzdialenosť od okolitých oblastí. Spájanie oblastí takto pokračuje až do splnenia podmienky pre ukončenie, ktorá je daná vzťahom 4.6

$$\frac{Z_a}{Z_{max}} > Y, \quad (4.6)$$

kde Z_a je aktuálna hodnota Z , Z_{max} je najväčšia z predchádzajúcich Z a Y je zvolený prah. Aby nedošlo k teoreticky možnému predčasnému ukončeniu etapy spájania (v prípade oblastí s identickými LBP/C histogramami) sa podmienka pre ukončenie pre prvých 10% možných spojení neoveruje.

Pre zlepšenie lokalizácie hraníc je použitá jednoduchá klasifikácia hraničných pixelov. Ako modely textúr slúžia segmenty, ktoré sú výstupom predchádzajúcej etapy, pričom do výpočtu modelových LBP/C histogramov sa nezahŕňajú okrajové oblasti, kde je pravdepodobnosť výskytu „cudzej“ textúry. Ak sa pixel obrazu nachádza na hranici aspoň dvoch odlišných segmentov, tzn. jeden z pixelov jeho štvor-okolia patrí do iného segmentu, je v jeho okolí o priemere d vypočítaný LBP/C histogram a jeho G-vzdialenosť od segmentov v rámci overovaného štvor-okolia. Ak sa označenie testovaného pixelu líši od označenia segmentu s najmenšou G-vzdialenosťou a zároveň je v jeho štvor-okolí aspoň jeden ďalší hraničný pixel, testovaný pixel sa priradí k najbližšiemu segmentu. Druhá z podmienok zabezpečuje hladšie prispôsobenie hraníc segmentov a znižuje pravdepodobnosť výskytu malých dier v segmentoch. V ďalšom kroku sa overuje okolie len tých pixelov, ktorých označenie sa v predchádzajúcom


kroku zmenilo. Klasifikácia pixelov sa zastaví v prípade, že žiaden z testovaných pixelov nezmení označenie alebo pri dosiahnutí maximálneho počtu zmien označenia. Tento počet je daný dvojnásobkom S_{min} , pretože je možné predpokladať, že odhad hranice po etape spájania môže byť najviac tak ďaleko od skutočnej hranice.

5 Testovanie metód

Funkčnosť algoritmov bola overená na jednom z najpoužívanějších štandardných texturálnych datasetov – Brodatz a následne boli algoritmy testované na nameraných fantómových dátach.

5.1 Dataset Brodatz

Z celej databázy bolo vybraných deväť obrázkov textúr, ktoré sú uvedené na obr. 5.1. Obrázky majú veľkosť 640×640 pixelov. Z každého obrazu bol vybraný rôzny počet výrezov rôznych rozmerov. Takto vytvorená databáza výrezov bola rozdelená na dve polovice. Jedna polovica bola použitá na vytvorenie databázy príznakov – modelové textúry, druhá na testovanie správnosti klasifikácie.



Obr. 5.1 Deväť testovaných textúr Brodatz [22]

5.2 Fantómové dáta

Z nameraných dát bolo vybraných 20 obrazov priečných rezov každého z gélov. Dáta boli snímané v režime, kedy jeden obraz vzniká priemerom sekvencie ôsmich obrazov scény. Výstupom tohto režimu sú dáta vo forme matice rozmerov 512×4096 , kde priemer ôsmich susedných stĺpcov tvorí jeden stĺpec výsledného obrazu. Z týchto dát boli vytvorené dve databázy: jedna pozostávajúca zo spriemerovaných obrazov a druhá

z jednotlivých obrazov sekvencií. Z každého z obrazov databázy bol vybratý rôzny počet výrezov rôznych rozmerov. Prvá polovica zo vzoriek každého z gélov bola použitá pre vytvorenie databázy príznakov, druhá pre overenie správnosti klasifikácie.

5.3 Klasifikácia - co-occurrence matice a lokálne spektrálne parametre

Ako už bolo spomenuté, funkčnosť algoritmu pre klasifikáciu bola overená na texturálnom datasete Brodatz. V tab. 5.1 je uvedená matica zámen, ktorá vyjadruje percentuálnu úspešnosť klasifikácie medzi rôznymi textúrami z tohto albumu navzájom. Klasifikácia bola realizovaná pomocou výpočtu Mahalanobisovej vzdialenosti, pričom bolo použitých všetkých 24 parametrov uvedených v kapitole 4.3.1.

Tab. 5.1 Matica zámen pre album Brodatz, veľkosť vzoriek 20×20

textúra č.	1	2	3	4	5	6	7	8	9
1	100	0	1,23	0	0	0	0	0	0
2	0	100	0	0	0	0	0	0	0
3	0	0	90,12	0	0	0	0	0	0
4	0	0	0	100	0	0	0	0	3,70
5	0	0	8,64	0	100	0	0	1,23	0
6	0	0	0	0	0	100	0	0	0
7	0	0	0	0	0	0	98,77	0	0
8	0	0	0	0	0	0	0	98,77	0
9	0	0	0	0	0	0	1,23	0	96,30

Základným problémom pri použití co-occurrence matíc je prevod surových dát na 8-bitový obraz. Dáta boli kvantované v intervale stanovenom na základe ich celkovej distribúcie:

$$\langle Q_{0,25} - 3 \times IQR; Q_{0,75} + 3 \times IQR \rangle, \quad (5.1)$$

kde $Q_{0,25}$ je dolný kvartil, $Q_{0,75}$ horný kvartil a $IQR = Q_{0,75} - Q_{0,25}$, tzv. medzikvartilové rozpätie (z angl. Interquartile range), ktoré ohraničuje interval, v ktorom sa nachádza 50% všetkých hodnôt distribúcie.

U Co-occurrence matíc bol testovaný vplyv vzdialenosti d medzi párami pixelov. Táto vzdialenosť by mala byť volená v závislosti na veľkosti primitív klasifikovanej textúry. Pre všetky tri vzdialenosti $d = 1$, $d = 2$ a $d = 3$ bola celková úspešnosť okolo 80%. V tab. 5.2 je uvedená matica zámen z testovania priemerovaných surových obrazov gélov č. 8-14 uvedených v tab. 4.1. Všetky parametre nemusia mať rovnakú schopnosť odlíšiť triedy medzi sebou, a preto je niekedy vhodnejšie skrátiť vektor

parametrov. Parametre sú vo vektore zoradené takto: 1-5 energia, entropia, korelačný koeficient, lokálna homogenita a kontrast pre prvý smer, 6-10, 11-15 a 16-20 to isté pre ďalšie smery, 20-24 výkon jednotlivých pásmach. Pre dosiahnutie najlepšej úspešnosti nebolo vzhľadom na veľký počet parametrov reálne skúšať všetky kombinácie. Preto bola overená úspešnosť klasifikácie zvlášť pre rôzne smery. Výsledky pre rôzne smery boli porovnateľné – štruktúra speklóv má pravdepodobne izotropický charakter. Ďalej bola overená úspešnosť klasifikácie pri použití parametrov získaných priemerom pre rôzne smery – zabezpečenie rotačnej invariantnosti metódy. Úspešnosť však bola horšia ako pri zahrnutí všetkých smerov naraz. Posledným spôsobom pre skrátenie vektoru parametrov bolo pokusné vynechávanie jednotlivých parametrov z vektoru plnej veľkosti. Pri zlepšení výsledku bol daný parameter vynechaný, pri zhoršení bol zasa vrátený do vektoru a vynechaný ďalší. Týmto spôsobom bol získaný aj vektor parametrov použitý pre klasifikáciu gélov uvedených v tab. 5.2.

Tab. 5.2 Matica zámien pre $d = 3$, veľkosť okolia 30×30 a vektor parametrov: 1, 10, 12, 13, 16, 18, 20, 21, 22, 23, 24.

číslo gélu	8	9	10	11	12	13	14
8	100	0	0	0	0	0	0
9	0	100	5	0	0	0	0
10	0	0	93,75	6,25	0	0	0
11	0	0	1,25	91,25	7,5	0	0
12	0	0	0	2,5	81,25	16,25	0
13	0	0	0	0	11,25	75	0
14	0	0	0	0	0	0	91,25

V tab. 5.3 sú uvedené najlepšie dosiahnuté výsledky pre agarózové gély bez intralipidu.

Tab. 5.3 Matica zámien pre $d = 1$, veľkosť okolia 30×30 a vektor parametrov: 1, 10, 12, 13, 16, 18, 20, 21, 22, 23, 24.

číslo gélu	1	2	3	4	5	6	7
1	100	0	0	0	0	0	0
2	0	100	0	0	0	0	0
3	0	0	46,25	10	1,25	17,5	23,75
4	0	0	5	26,25	13,75	11,25	0
5	0	0	7,5	38,75	67,5	33,75	0
6	0	0	32,5	25	17,5	37,5	1,25
7	0	0	8,75	0	0	0	75

Vhodnosť použitia co-occurrence matíc pre analýzu speklóv bola počas tvorby tejto

práce prehodnotená, pretože táto metóda je závislá na jase obrazu a teda nevyhodnocuje len textúru speklôv. Metóda by teda odlišila rovnakú textúru s rôznym jasom ako dve rozdielne textúry a tým pádom je problematické určiť či sa jedná len o zmenu jasú, alebo o zmenu textúry. Tento problém by čiastočne mohola riešiť korekcia na útlm, ktorá bola implementovaná podľa [23], ktorá je založená na získaní priebehu útlmu v jednotlivých stĺpcoch obrazu priemerovaním v posuvnom okne a následnom pričítaní inverzného priebehu k originálnemu stĺpcu v obraze. Tento postup však zanáša do obrazu určitú chybu. Ďalším problémom je závislosť funkčnosti metódy na predspracovaní obrazu a ako už bolo uvedené potreba jeho prevodu na 8-bitový obraz.

5.4 Klasifikácia - Lokálne binárne vzory

Úspešnosť klasifikácie bola testovaná implementovanými operátormi *LBP*: $LBP_{8,1}$, $LBP_{12,2}$ a $LBP_{16,3}$, samostatne, alebo v kombinácii s operátormi pre vyhodnotenie kontrastu: $C_{8,1}$, $C_{12,2}$ a $C_{16,3}$. Pre porovnanie boli testované aj prevzaté operátory [24]: $LBP_{P,R}^{ri}$, $LBP_{P,R}^{u2}$, $LBP_{P,R}^{riu2}$ a $VAR_{P,R}$.

Vzhľadom na to, že výstupy operátorov *LBP* môžu nadobúdať len diskkrétne hodnoty v rozsahu danom konkrétnou verziou operátora a počtom susedov P , nie je potrebná žiadna kvantizácia a z výstupného parametrického obrazu po aplikácii *LBP* operátora získaný histogram. Výstupy operátorov pre hodnotenie kontrastu $C_{P,R}$ a $VAR_{P,R}$ však môžu nadobúdať hodnoty zo spojitého intervalu s rozsahom závislým na vstupných hodnotách – hodnotách analyzovaného obrazu, a preto je potrebné tento rozsah kvantovať na určitý počet úrovní q . Najprv bola získaná celková distribúcia výstupných hodnôt aplikovaním operátora na celú testovaciu množinu (prvá polovica vzoriek každého z gélov). Následne bol získaný parametrický priestor kvantovaný jedným z troch nasledujúcich spôsobov:

- rozdelenie celého rozsahu od $\langle min; max \rangle$ na q rovnako veľkých intervalov,
- rozdelenie intervalu 5.2 na q rovnako veľkých intervalov

$$\langle Q_{0,25} - 1,5 \times IQR; Q_{0,75} + 1,5 \times IQR \rangle, \quad (5.2)$$

kde $Q_{0,25}$, $Q_{0,75}$ a IQR majú rovnaký význam ako už bolo uvedené vyššie,


- rozdelenie rozsahu na intervaly s rovnakým počtom prvkov, teda na intervaly ohraničené $100/q$ percentilmi.

Je možné predpokladať, že prvý spôsob nebude vhodný ak sa v rozdelení vyskytujú odľahlé hodnoty. Druhý spôsob sa používa v štatistike pre identifikáciu odľahlých hodnôt – v prípade kvantovania je zbytočné vytvoriť interval, v ktorom sa

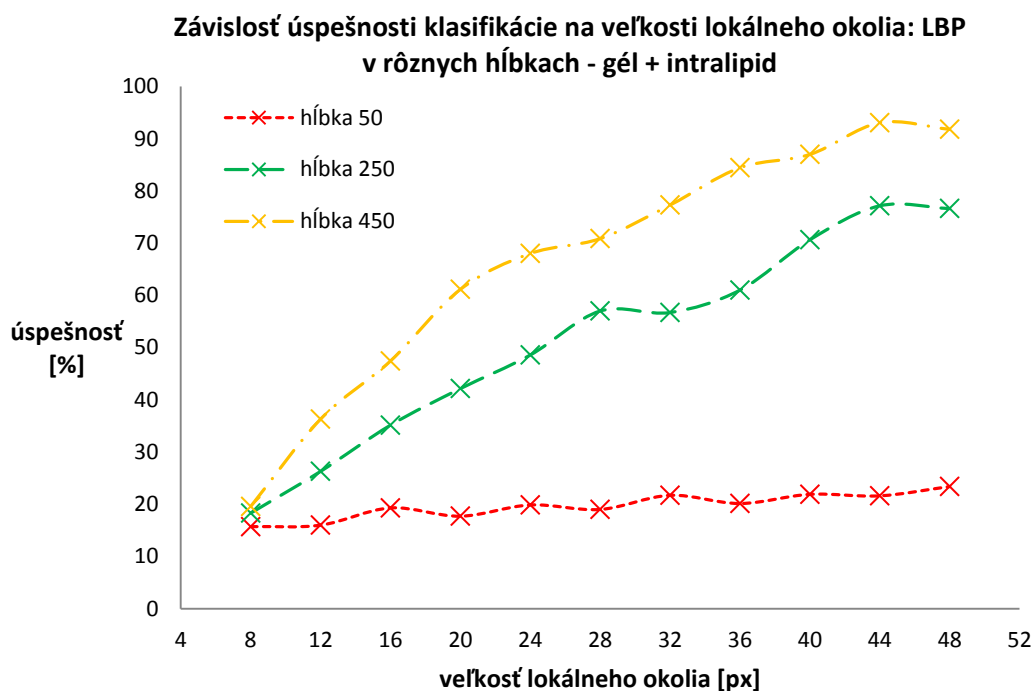
bude nachádzať veľmi malé množstvo hodnôt. Tretí spôsob bude pravdepodobne najvhodnejší, pretože poskytuje najväčšie rozlíšenie kvantizácie [14].

Zo všetkých možností mala najlepšie výsledky kombinácia operátorov $LBP_{8,1}$ a $C_{8,1}$ s tretím spôsobom kvantovania a preto budú v nasledujúcom texte hodnotené výsledky len tejto kombinácie. Porovnateľné výsledky dosahovala kombinácia operátora $LBP_{8,1}$ s $VAR_{8,1}$ s rovnakým spôsobom kvantovania.

Zásadný vplyv na schopnosť metódy charakterizovať textúru má veľkosť okolia, z ktorého sa odvodzujú popisné parametre. Na obr. 5.2 a obr. 5.3 je uvedená závislosť úspešnosti klasifikácie na veľkosti lokálneho okolia v rozsahu rozmerov 8×8 až 48×48 pixelov. Na celom rozsahu bolo použité kvantovanie na štyri úrovne, kedy klasifikácia dosahovala najlepšie výsledky. Tieto závislosti boli získané pri testovaní priemerovaných surových obrazov gélov 8-14 uvedených v tab. 4.1. Vzorky boli vyberané v množine pre vytvorenie tried aj testovacej množine vždy v rovnakej hĺbke. Horný okraj vzoriek mal polohu: 50, 250, a 450 pixelov od horného okraja obrazu. Z každého obrazu bolo vybraných 10 vzoriek s rozstupmi v horizontálnom smere 20 pixelov, pričom pri väčších vzorkách sa rozstupy podľa potreby zmenšili. Vo výsledku teda pozostávala testovacia množina aj množina pre vytvorenie tried zo 100 vzoriek.



Obr. 5.2 Úspešnosť klasifikácie kombinácie operátorov $LBP_{8,1}$ a $C_{8,1}$



Obr. 5.3 Úspešnosť klasifikácie operátora $LBP_{8,1}$

Celková úspešnosť zobrazená na vyššie uvedených grafoch má pri vzájomnej klasifikácii siedmich gélov len obmedzenú výpovednú hodnotu. V tab. 5.4 sú uvedené matice zámien, ktoré vyjadrujú percentuálnu úspešnosť klasifikácie medzi rôznymi géľmi navzájom.

Tab. 5.4 Matice zámien $LBP_{8,1}$ a $C_{8,1}$, počet kvant. úrovní kontrastu: 4, veľkosť okolia: 24×24 , hĺbka: a) 50, b) 250, c) 450.

číslo gélu	8	9	10	11	12	13	14
8	98	0	0	0	0	0	0
9	2	93	3	0	0	0	0
10	0	7	87	6	0	0	0
11	0	0	10	81	6	0	0
12	0	0	0	12	76	20	0
13	0	0	0	1	18	80	2
14	0	0	0	0	0	0	98

a)

číslo gélu	8	9	10	11	12	13	14
8	100	0	0	0	0	0	0
9	0	96	0	0	0	0	0
10	0	4	99	1	0	0	0
11	0	0	1	73	21	0	0
12	0	0	0	25	69	17	0
13	0	0	0	1	10	76	22
14	0	0	0	0	0	7	78

b)

číslo gélu	8	9	10	11	12	13	14
8	98	0	0	0	0	0	0
9	2	91	1	0	0	0	0
10	0	9	98	0	0	0	2
11	0	0	0	73	13	6	8
12	0	0	0	25	74	21	4
13	0	0	0	2	13	52	24
14	0	0	1	0	0	21	62

c)

Z vyššie uvedenej tabuľky je zrejmé, že schopnosť rozlíšiť rôzne gély v rovnakej hĺbke je pri danej veľkosti pomerne dobrá. Klasifikácia vzoriek z testovacej množiny, ktorá bola vytvorená v inej hĺbke ako triedy však úplne zlyháva. V tab. 5.5 je uvedená matica zámien pre klasifikáciu vzoriek z hĺbky 250 do tried vytvorených zo vzoriek v hĺbke 50. Tieto výsledky potvrdzujú, že charakter speklav sa mení s hĺbkou obrazu ako bolo

uvedené v kapitole 1.4.1.

Tab. 5.5 Matica zámen $LBP_{8,1}$ a $C_{8,1}$, počet kvant. úrovní kontrastu: 4, veľkosť okolia: 24×24 , hĺbka testovaných vzoriek: 250, hĺbka vzoriek pre vytvorenie tried: 50.

číslo gélu	8	9	10	11	12	13	14
8	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0
14	100	100	100	100	100	100	100

V tab. 5.6 je uvedená matica zámen pre agarózové gély bez intralipidu. Vzorky boli vyberané v hĺbke 50 pixelov od horného okraja obrazu. Tieto výsledky boli dosiahnuté pri analýze surových dát.


Tab. 5.6 Matica zámen $LBP_{8,1}$ a $C_{8,1}$, počet kvant. úrovní kontrastu: 3, veľkosť okolia: 24×24 , hĺbka testovaných vzoriek: 50, hĺbka vzoriek pre vytvorenie tried: 50

Číslo gélu	1	2	3	4	5	6	7
1	100	0	0	0	0	0	0
2	0	100	0	0	0	0	0
3	0	0	37	20	21	23	13
4	0	0	19	32	36	21	0
5	0	0	6	22	24	15	0
6	0	0	15	21	14	29	2
7	0	0	23	5	5	12	85

5.5 Segmentácia - Lokálne binárne vzory


Z dôvodu predpokladu závislosti textúry spekllov na hĺbke v obraze, ktorá sa ako bolo uvedené v predchádzajúcej podkapitole potvrdila, bola pre segmentáciu zvolená metóda bez učiteľa. Tým odpadla potreba vytvorenia modelových textúr pre rôzne hĺbky zvlášť, čo by bolo pomerne ťažkopádne.

Segmentácia bola testovaná na obrazoch umelo vytvorených zložením obrazov dvoch rôznych gélov. Do stredu jedného obrazu bol umiestnený kruhový výrez druhého obrazu. Jeden z testovaných obrazov je uvedený na obr. 5.4.




Obr. 5.4 Umelo vytvorený obraz – kombinácia gélov č. 8 a č.11

Ako už bolo uvedené pri popise princípu tohto algoritmu v kapitole 4.4, vlastnosti segmentácie je možné upraviť nastavením piatich parametrov: prahov X a Y , veľkosti najmenších častí pri hierarchickom delení S_{min} , veľkosti priemeru d okolia hraničných pixelov, ktoré sú klasifikované v poslednom kroku segmentácie a počtu kvantizačných úrovní. Prah X je vhodné voliť radšej menší, a rozdeliť obraz na viac podoblastí, pretože nasledujúca etapa spájania je schopná zbytočne rozdelenú uniformnú oblasť zasa spojiť. Oprava chyby vzniknutej nerozdelením oblasti obsahujúcej rôzne textúry však nie je možná. Pre segmentáciu fantómových obrazov bola vo väčšine prípadov dostatočne nízka hodnota $X = 1,3$. Veľkosť S_{min} je potrebné voliť s ohľadom na schopnosť metódy odlíšiť dve rôzne textúry. Prijateľná úspešnosť je však, ako je možné vidieť na obr. 5.2, dosiahnutá až od veľkosti 28×28 . Z toho vyplýva, že pri danej veľkosti bude odhad hraníc medzi rozličnými textúrami po druhej etape segmentácie veľmi hrubý. To čo bolo uvedené pre voľbu S_{min} platí aj pre voľbu veľkosti priemeru d pre klasifikáciu hraničných pixelov v tretej etape. Je však potrebné zvoliť kompromis, pretože klasifikácia s príliš malou veľkosťou okolia je nestabilná a produkuje členité hranice a diery vo vnútri výsledných segmentov, zatiaľ čo pri veľkom okolí je klasifikácia stabilná a hranice sú hladké, avšak odhad ich polohy môže byť nepresný. Výsledný obraz je po tretej etape zmenšený na každej strane o $d/2$ pixelov. Na obr. 5.5 je zobrazený výsledok prvej etapy segmentácie.




Obr. 5.5 Výsledok prvej etapy segmentácie – hierarchické delenie, gély č. 8 a č. 13

Na nasledujúcich obrazoch je uvedený výsledok po druhej a tretej fáze segmentácie.



Obr. 5.6 Výsledok druhej fázy segmentácie – spájanie oblastí, gély č. 8 a č. 13




Obr. 5.7 Výsledok tretej fázy – klasifikácia pixelov, hranice segmentov, gély č. 8 a č. 13



Obr. 5.8 Výsledok tretej fázy – klasifikácia pixelov, segmenty, gély č. 8 a č. 13

Vyššie uvedené výsledky segmentácie boli dosiahnuté pri nasledujúcich nastaveniach: $X = 1,3$; $Y = 2,5$; $S_{min} = 28$; $d = 25$; kontrast bol kvantovaný na 4 úrovne. Po hierarchickom delení je síce obraz zbytočne rozdelený aj v uniformných oblastiach, čo je však lepší prípad ako keby boli za uniformné považované aj oblasti zahŕňajúce obidva gély, čo sa nestalo. Výstupom druhej etapy je pomerne hrubý, ale správny odhad hraníc segmentov. Ako je možné vidieť na obrázkoch v strede

a v spodnej časti obrazu posledná etapa upresnila polohu hraníc, v hornej časti obrazu však zlyháva a odhad hraníc segmentov ešte zhoršuje. Tento výsledok segmentácie patrí medzi najlepšie. Ďalšie obrázky výsledkov segmentácie sú uvedené v prílohe. Funkčnosť bola testovaná aj na textúrach z datasetu Brodatz. Na obr. 5.9 je uvedený výsledok segmentácie obrazu umelo vytvoreného z piatich textúr: D77, D16, D4, D29, D53. Úspešnosť segmentácie v tomto prípade dosiahla 99%.



Obr. 5.9 Výsledok segmentácie obrazu tvoreného z piatich textúr Brodatz.

Záver

Cieľom tejto práce bolo zoznámiť sa s princípom optickej koherentnej tomografie, jej aplikáciami a charakterom obrazov, preštudovať a popísať princíp vzniku speklav v obrazoch a popísať metódy pre ich analýzu. Praktická časť práce pozostávala z implementovania metód analýzy speklav, prípravy fantómov, namerania fantómových dát a otestovania funkčnosti implementovaných algoritmov. V programovom prostredí MATLAB boli implementované dve metódy textúrnej analýzy pre účely klasifikácie a jedna metóda pre segmentáciu obrazov z optickej koherentnej tomografie. Pre analýzu boli použité prístupy založené na co-occurrence maticiach v kombinácii s parametrami odvodenými vo frekvenčnej oblasti a na lokálnych binárnych vzoroch v kombinácii s operátormi vyhodnocujúcimi lokálny kontrast. Implementovaný segmentačný algoritmus patrí medzi regiónovo orientované, konkrétne sa jedná o segmentáciu delením a zlučovaním oblastí. Funkčnosť implementovaných algoritmov bola overená na jednom z najpoužívanejších štandardných texturálnych datasetov – Brodatz. Následne boli algoritmy testované na nameraných fantómových dátach. Pre vhodné vlastnosti a dostupnosť bol ako materiál na prípravu fantómov zvolený agarózový gél s rôznymi koncentraciami, ktorý je bežne využívaný pri gélovej elektroforéze. Pre dosiahnutie rôznych optických vlastností boli pripravené aj gély s rôznym obsahom intralipidu – vnútrožilnej tukovej emulzie.

Úspešnosť klasifikácie bola relatívne dobrá, avšak až pri pomerne veľkých rozmerov klasifikovaných vzoriek a rovnakej vertikálnej polohe. Lepšie výsledky boli dosiahnuté pri klasifikácii gélov s intralipidom a preto je možné predpokladať, že zmena koncentrácie agarózy nemá dostatočný vplyv na koeficient rozptylu gélu. Ďalej bolo overené, že textúra speklav sa mení v závislosti na zobrazovanej hĺbke. Už spomenutá závislosť úspešnosti klasifikácie na veľkosti rozmerov lokálneho okolia, v ktorom je analyzovaná textúra speklav, má pri segmentácii za následok len veľmi hrubý odhad hraníc segmentov. Z tohto dôvodu zlyháva aj posledný krok v algoritme segmentácie, ktorý by mal hranice upresniť. Na základe dosiahnutých výsledkov je možné konštatovať, že textúrna analýza speklav založená na vyššie spomenutých metódach nie je pre účely segmentácie obrazov z OCT veľmi vhodná. Nie je však možné ani s určitosťou povedať, ako verne vytvorené fantómy modelujú vlastnosti tkanív.

Literatúra

1. TOMLINS, P. H. WANG, R. K. Theory, developments and applications of optical coherence tomography. *Journal of Physics D: Applied Physics*. 2005, **38** (15), 2519 - 2535.
2. KOLÁŘ, R. *Lékařská diagnostická technika*. 2007. ISRC ABM 07-91.
3. HALLIDAY, D. RESNICK, R. WALKER, J. *Fyzika: 36 Interference*. Brno: VUTIUM, 2000. ISBN 80-214-1868-0.
4. WALTHER, J. Optical coherence tomography in biomedical research. *Analytical and Bioanalytical Chemistry*. Springer-Verlag, 2011, **400** (9), 2721 - 2743.
5. FERCHER, A. F. Optical coherence tomography – development, principles, applications. *Zeitschrift für Medizinische Physik*. 2010, **20** (4), 251 - 276.
6. MARSCHALL, S. SANDER, B. Optical coherence tomography - current technology and applications in clinical and biomedical *Analytical and Bioanalytical Chemistry*. 2011, č. 400, s. 2699 - 2720.
7. PIRCHER, M. GÖTZINGER, E. Speckle Reduction in Optical Coherence Tomography by Frequency Compounding. *Journal of Biomedical Optics*. 2003, **8** (3), 565 - 569.
8. SCHMITT, J. M. XIANG, S. H. Speckle in Optical Coherence Tomography: An Overview. *Journal of Biomedical Optics*. 1999, **4** (1), 95 - 105.
9. FERCHER, A.F. DREXLER, W. Optical coherence tomography - principles and applications. *Reports on Progress in Physics*. Institute of Physics Publishing, 2003, č. 66, s. 239 - 303.
10. GOSSAGE, K. W. SMITH, C. M. Texture analysis of speckle in optical coherence tomography images of tissue phantoms. *Physics in Medicine and Biology*. 2006, č. 51, s. 1563 - 1575.
11. SZKULMOWSKI, M. GORCZYNSKA, I. Efficient reduction of speckle noise in Optical Coherence Tomography. *Optics Express*. 2012, **20** (2), 1337 - 1359.
12. JAN, J. *Medical Image Processing, Reconstruction and Restoration: Concepts and Methods*. Boca Raton : Taylor & Francis, 2006, 730 s.. ISBN 0-8247-5849-8.
13. MÄENPÄÄ, T. *The local binary pattern approach to texture analysis - extensions and applications*. Oulu (Finland): 2003. Disertační práce. University of Oulu, Infotech Oulu and Department of Electrical and Information Engineering. 78 s..

14. OJALA, T. M. PIETIKAINEN A T. MAENPAA. Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. *IEEE Transactions On Pattern Analysis And Machine Intelligence*. IEEE, 2002, **24** (7), 971 - 987. ISSN 0162-8828.
15. OJALA, T.. M. P. Unsupervised texture segmentation using feature distributions. *Pattern Recognition*. SciVerse ScienceDirect Journals , 1999, **32** (3), 477 - 486. ISSN 0031-3203.
16. GALLO, V. *Segmentace ultrazvukových sekvencí*. Brno: 2013. Bakalárska práca. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Vedoucí práce Ing. Martin Mézl. 48 s..
17. NARAYANAN, J. X. - Y. LIU A J. - Y. XIONG. Determination of agarose gel pore size: Absorbance measurements vis a vis other techniques. *Journal of Physics: Conference Series*. 1. ledna 2006, **28** (1), 83 - 86. ISSN 17426588.
18. Návod k použití CEB DNA Electrophoresis kit v2.1! In: *Central European Biosystems s.r.o.* [online]. Dostupné také z: <http://www.cebiosys.cz/products/ceb-dna-electrophoresis-kit/>
19. DONG, M. L.; K. G. GOYAL ET AL. Accurate in situ measurement of complex refractive index and particle size in intralipid emulsions. *Journal of Biomedical Optics*. 2013, **18** (8), 7.
20. MELOUN, M. *Počítačová analýza vícerozměrných dat v oborech přírodních, technických a společenských věd* [Učební texty ke kurzu]. Pardubice: Univerzita Pardubice, 2011, 92 s..
21. PIETIKÄINEN, M.; T. OJALA A Z. XU. Rotation-invariant texture classification using feature distributions. *Pattern Recognition*. 2000, **33** (1), 43 - 52. ISSN 0031-3203.
22. HE. D. - CH. SAFIA, A. *Multiband Texture Database* [online]. [cit. 2014-12]. Dostupné z: http://multibandtexture.recherche.usherbrooke.ca/images/Original_Brodatz.zip
23. CHANG, S.; C. FLUERARU ET AL. Attenuation compensation for optical coherence tomography imaging. *Optics Communications*. 2009, **282** (23), 4503 - 4507. ISSN 0030-4018.
24. OJALA T.; M. PIETIKÄINEN A T. MÄENPÄÄ. *A general Local Binary Pattern (LBP) implementation for Matlab*. verze 2015. Dostupné také z: <http://www.cse.oulu.fi/CMV/Downloads/LBP Matlab>

Zoznam príloh

A Elektronická časť diplomovej práce	45
A.1 Zdrojové texty.....	45
A.2 Funkcie	45
A.3 Dáta.....	46
B Výsledky segmentácie	48

A Elektronická časť diplomovej práce

A.1 Zdrojové texty

- fantom_kruh.m
- fantom_kruh_brodatz.m
- hodnotenie_segmentacie.m
- klasifikacia_co_oc_br_knn.m
- klasifikacia_co_oc_br_mahal_dist.m
- klasifikacia_co_oc_knn_7.m
- klasifikacia_co_oc_mahal_dist_7.m
- klasifikacia_lbp_br.m
- klasifikacia_lbp_br_joint.m
- klasifikacia_lbp_joint_7.m
- kompenzacia_utlmu_databazy.m
- prezeranie_vysledkov.m
- segmentacia_lbp_br_final.m
- segmentacia_lbp_oct_final.m
- vyber_obrazov_agaroza_gel.m
- vyber_obrazov_intralipid_gel.m
- vytvorenie_databazy_co_oc_br_testy.m
- vytvorenie_databazy_co_oc_br_triedy.m
- vytvorenie_databazy_co_oc_oct_testy.m
- vytvorenie_databazy_co_oc_oct_triedy.m
- vytvorenie_databazy_co_oc_oct_testy_kvantizacia.m
- vytvorenie_databazy_co_oc_oct_triedy_kvantizacia.m
- vytvorenie_databazy_lbp_br_testy.m
- vytvorenie_databazy_lbp_br_triedy.m
- vytvorenie_databazy_lbp_oct_testy.m
- vytvorenie_databazy_lbp_oct_triedy.m

A.2 Funkcie

- cont.m [24]
- frgread.m
- frgread_surove.m
- g_stat.m
- g_stat_co.m


- getmapping.m [24]
- joint_histogram_d.m
- kompenzacia_utlmu.m
- kontrast_8_1.m
- kontrast_12_2.m
- kontrast_16_3.m
- kvantizacia_C.m
- kvantizacia_C_kvantily_iqr.m
- kvantizacia_C_median_iqr.m
- kvantizacia_C_percentily.m
- kvantizacia_lbp.m
- lbp.m [24]
- lbp_8_1.m
- lbp_12_2.m
- lbp_16_3.m
- n_susedia_s.m
- p_klasifikacia.m
- stvrtenie.m

A.3 Dáta


- databaza_obr_oct_agaroza_gel_log_10.mat
- databaza_obr_oct_agaroza_gel_surove.mat
- databaza_obr_oct_intralipid_gel_log10_bez_priemeru.mat
- databaza_obr_oct_intralipid_gel_log10_priemer.mat
- databaza_obr_oct_intralipid_gel_surove_bez_priemery.mat
- databaza_obr_oct_intralipid_gel_surove_priemer.mat
- databaza_testov_co_oc_agaroza_gel_surove.mat
- databaza_tried_co_oc_agaroza_gel_surove.mat
- databaza_testov_lbp_intralipid_gel_surove_priemer.mat
- databaza_tried_lbp_intralipid_gel_surove_priemer.mat
- obr_na_segmentaciu_oct_gi_p_s_1_2.mat
- obr_na_segmentaciu_oct_gi_p_s_1_3.mat
- obr_na_segmentaciu_oct_gi_p_s_1_4.mat
- obr_na_segmentaciu_oct_gi_p_s_1_5.mat
- obr_na_segmentaciu_oct_gi_p_s_1_6.mat
- obr_na_segmentaciu_oct_gi_p_s_1_7.mat
- obr_na_segmentaciu_oct_gi_p_s_2_1.mat

- obr_na_segmentaciu_oct_gi_p_s_3_1.mat
- obr_na_segmentaciu_oct_gi_p_s_4_1.mat
- obr_na_segmentaciu_oct_gi_p_s_5_1.mat
- obr_na_segmentaciu_oct_gi_p_s_6_1.mat
- obr_na_segmentaciu_oct_gi_p_s_7_1.mat
- vysledok_segmentaxie_gi_p_s_1_2.mat
- vysledok_segmentaxie_gi_p_s_1_3.mat
- vysledok_segmentaxie_gi_p_s_1_4.mat
- vysledok_segmentaxie_gi_p_s_1_5.mat
- vysledok_segmentaxie_gi_p_s_1_6.mat
- vysledok_segmentaxie_gi_p_s_1_6_2.mat
- vysledok_segmentaxie_gi_p_s_1_6_s_p_class.mat
- vysledok_segmentaxie_gi_p_s_1_7_2.mat
- vysledok_segmentaxie_gi_p_s_2_1.mat
- vysledok_segmentaxie_gi_p_s_3_1.mat
- vysledok_segmentaxie_gi_p_s_4_1.mat
- vysledok_segmentaxie_gi_p_s_5_1.mat
- vysledok_segmentaxie_gi_p_s_6_1.mat
- vysledok_segmentaxie_gi_p_s_7_1.mat
- vysledok_segmentacie_gi_p_s_7_1_2_p_class1.mat
- vysledok_segmentacie_gi_p_s_7_1_2_p_class2.mat
- vysledok_segmentacie_gi_p_s_7_1_2_p_class3.mat
- D79.gif
- D77.gif
- D68.gif
- D53.gif
- D29.gif
- D24.gif
- D19.gif
- D16.gif
- D4.gif


B Výsledky segmentácie



Obrázok 1 Výsledok prvej etapy segmentácie – hierarchické delenie, gély č. 8 a č. 14




Obrázok 2 Výsledok druhej fázy segmentácie – spájanie oblastí, gély č. 8 a č. 14




Obrázok 3 Výsledok tretej fázy – klasifikácia pixelov, hranice segmentov, gély č. 8 a č. 14




Obrázok 4 Výsledok tretej fázy – klasifikácia pixelov, segmenty, gély č. 8 a č. 14




Obrázok 5 Výsledok prvej etapy segmentácie – hierarchické delenie, gély č. 14 a č. 8



Obrázok 6 Výsledok druhej fázy segmentácie – spájanie oblastí, gély č. 14 a č. 8



Obrázok 7 Výsledok tretej fázy – klasifikácia pixelov, hranice segmentov, gély č. 14 a č. 8



Obrázok 8 Výsledok tretej fázy – klasifikácia pixelov, segmenty, gély č. 14 a č. 8