

Západočeská univerzita v Plzni  
Fakulta aplikovaných věd

# Obrazová analýza parenchymatózních orgánů a jejich cévní struktury

Ing. Miroslav Jiřík

disertační práce  
k získání akademického titulu doktor  
v oboru Kybernetika

*školitel: Doc. Ing. Miloš Železný, Ph.D.*  
Katedra kybernetiky

Plzeň, 2016

---

University of West Bohemia  
Faculty of Applied Sciences

# Image analysis of the parenchymatous organs and their blood-vessel structure

Ing. Miroslav Jiřík

A dissertation thesis submitted in partial fulfillment  
of the requirements for the degree of Ph.D.  
Cybernetics

*Supervised by: Doc. Ing. Miloš Železný, Ph.D.*  
Department of Cybernetics

Pilsen, 2016

---

---

## Prohlášení

Prohlašuji, že jsem tuto disertační práci vypracoval samostatně a výhradně s použitím citovaných pramenů, literatury a dalších odborných zdrojů. Disertační práce byla vypracována pod vedením Doc. Ing. Miloše Železného, Ph.D. na Západočeské univerzitě v Plzni.

V Plzni dne

---

## Resumé

Pro pochopení dějů uvnitř parenchymatózniých orgánů hraje důležitou roli prokvení. Tato práce je věnována tvorbě geometrických modelů těchto orgánů a jejich cévní struktury s ohledem na modelování jejich prokvení. Navržena je metoda pro lokalizaci parenchymů v obrazech z trojrozměrných zobrazovacích metod. Nejprve je přibližně určena poloha parenchymu vzhledem k významným anatomickým strukturám těla. Jemná segmentace pak rozšiřuje metodu Graph-Cut a pracuje na více měřítkách. To umožňuje snížit výpočetní nároky pro rozměrná vstupní data. Dále je popsána metoda extrakce zjednodušeného modelu cévního stromu. Tento strom pak slouží pro modelování prokvení. Byla navržena poloautomatická metoda pro kvantitativní popis mikrostruktury parenchymů. Jejím prostřednictvím lze při hodnocení mikrokoroziivních preparátů parenchymatózniých orgánů získávat výsledky srovnatelné s běžnými manuálními stereologickými metodami.

Klíčová slova: segmentace, perfuze, prokvení, model, Graph-Cut, cévní strom

---

## Summary

Blood flow is important for understanding the processes inside parenchymatous organs. The main goal of this thesis is the creation of geometric models of these organs and their blood-vessel structure with respect to the modeling of blood flow. We introduce a method for parenchyma localization in 3D medical imaging data. First a coarse localization is expressed via relative positions to significant anatomical structures of a body. Then an accurate segmentation method which extends Graph-Cut and works on multiple scales is applied. This allows to reduce computational requirements for large input data. Next, a method for extraction of a simplified model of a vascular tree is used. From this tree a blood flow is modeled. We also introduce a semi-automatic method for quantitative description of parenchyma microstructure. Experiments have shown that our semi-automatic method for quantitative description of micro-corrosion casts is comparable to the conventional manual method.

Keywords: segmentation, perfusion, blod flow, model, Graph-Cut, vascular tree

## Poděkování

Na tomto místě bych chtěl poděkovat Miloši Železnému za podnětné připomínky.



# Obsah

Seznam obrázků	xii
Seznam tabulek	xvi
Zkratky	1
Glossary	3
<b>1 Úvod</b>	<b>4</b>
1.1 Cíle práce . . . . .	6
1.2 Struktura textu . . . . .	7
<b>2 Parenchymatozní orgány břišní dutiny</b>	<b>9</b>
2.1 Slezina . . . . .	9
2.2 Ledviny . . . . .	11
2.3 Játra . . . . .	12
2.3.1 Funkce jater . . . . .	13
2.3.2 Průtok krve játry . . . . .	13
2.3.3 Chirurgie jater . . . . .	16
2.4 Spolupráce s Fakultní nemocnicí v Plzni . . . . .	17
<b>3 Trojrozměrné zobrazovací metody a modelování proudění</b>	<b>19</b>
3.1 Výpočetní tomografie . . . . .	20
3.2 Magnetická rezonance . . . . .	23
3.3 Srovnání CT a MR z pohledu počítačového vidění . . . . .	26
<b>4 Metody počítačového vidění pro zpracování trojrozměrných obrazů</b>	<b>28</b>
4.1 Příznaky pro popis oblastí . . . . .	28
4.1.1 Statistický popis textury . . . . .	29
4.1.2 Geometrické metody . . . . .	42
4.1.3 Metody založené na modelech . . . . .	46
4.1.4 Metody vycházející ze zpracování signálů . . . . .	50
4.1.5 Zhodnocení metod pro popis textur . . . . .	57
4.2 Strojová segmentace objemových obrazových dat . . . . .	58

---

4.2.1	Metody vycházející z globální znalosti o obraze . . . . .	58
4.2.2	Hranově založené přístupy k segmentaci . . . . .	60
4.2.3	Oblastně založené přístupy k segmentaci . . . . .	61
4.2.4	Active Contour Model . . . . .	61
4.2.5	Graph-Cut . . . . .	61
<b>5</b>	<b>Makroskopický tvarový model parenchymatózních orgánů</b>	<b>66</b>
5.1	Odhad velikosti jater . . . . .	66
5.1.1	Odhad objemu jater na základě plochy těla . . . . .	67
5.1.2	Manuální volumetrie . . . . .	67
5.2	Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu . . . . .	69
5.2.1	Určení polohy v těle na základě segmentace základních anatomických struktur . . . . .	69
5.2.2	Texturní příznaky . . . . .	74
5.2.3	Tvorba příznakového vektoru . . . . .	75
5.2.4	Segmentace parenchymu . . . . .	76
5.2.5	Víceměřítková segmentace pomocí Graph-Cut . . . . .	78
5.2.6	Dvoustranná texturní segmentační kombinující Gabor-wavelet a Graph-Cut . . . . .	80
5.2.7	Přesná segmentace na okrajích . . . . .	83
5.3	Vyhodnocení . . . . .	84
<b>6</b>	<b>Geometrický model cévního řečiště</b>	<b>86</b>
6.1	Model cévního stromu . . . . .	86
6.1.1	Reprezentace cévních struktur . . . . .	89
6.2	Modelování perfuze jater . . . . .	90
6.2.1	Modelování proudění v makroskopickém měřítku . . . . .	90
6.2.2	Mikroskopický model proudění . . . . .	92
6.2.3	Geometrický model pro modelování prokrvení . . . . .	93
6.3	Analýza mikrovaskulatury . . . . .	93
6.4	Příprava vzorků pro vytvoření modelu cévní mikrostruktury . . . . .	95
6.5	Poloautomatická kvantitativní analýza tkáňových vzorků . . . . .	97
6.5.1	Volba oblasti zájmu . . . . .	99
6.5.2	Měření parametrů cévního segmentu . . . . .	101
6.5.3	Kvantitativní popis cévní mikrostruktury . . . . .	101
6.6	Vyhodnocení . . . . .	103
<b>7</b>	<b>Provedené experimenty</b>	<b>104</b>
7.1	Testovací data . . . . .	104
7.2	Experimenty - makroskopický model parenchymu . . . . .	106
7.3	Kontrola měření objemu . . . . .	110
7.4	Víceměřítková Graph-Cut segmentace . . . . .	110
7.5	Texturní analýza kombinující Gabor-wavelety a Graph-Cut . . . . .	116

---

7.6	Texturní deskriptory pro parenchymatózní orgány . . . . .	117
7.7	Kvantitativní popis mikrostruktury cévního řečiště jaterního parenchymu	121
7.8	Vyhodnocení experimentů . . . . .	121
<b>8</b>	<b>Aplikační přínos</b>	<b>124</b>
8.1	Segmentace parenchymatózních orgánů . . . . .	124
8.2	Aplikace Lisa . . . . .	125
8.3	Aplikace QuantAn . . . . .	125
8.4	Další moduly . . . . .	125
<b>9</b>	<b>Závěr</b>	<b>129</b>
9.1	Dosažené cíle . . . . .	130
9.1.1	Segmentace parenchymu . . . . .	130
9.1.2	Model cévního systému . . . . .	130
9.1.3	Geometrický model pro modelování prokrvení . . . . .	130
9.1.4	Kvantitativní popis jaterní mikrostruktury . . . . .	131
9.2	Navazující výzkum . . . . .	131
	<b>Literatura</b>	<b>132</b>
	<b>10 Přílohy</b>	<b>143</b>
	<b>Seznam publikovaných prací</b>	<b>144</b>
	<b>Seznam ostatních prací</b>	<b>146</b>

# Seznam obrázků

1.1	Incidence a mortalita zhoubných nádorů jater a žlučových cest na území ČR, zdroj: [32], zdroj primárních dat: [1] . . . . .	5
1.2	Počet případů zhoubných nádorů jater a žlučových cest, zdroj: [32], zdroj primárních dat: [1] . . . . .	6
2.1	Slezina, převzato z [115] . . . . .	10
2.2	Ledvina, převzato z [115] . . . . .	11
2.3	Poloha jater v břišní dutině, AX - řez v pravé přední axiální čáře, P.dx. řez v pravé parasternální čáře, P.sin. řez v levé parasternální čáře, C – tlusté střevo (colon), D – dvanáctník (duodenum), G – žaludek (gaster), K – vyústění jícnu do žaludku (cardia), P – slinivka (pancreas), R – ledvina (ren), převzato z [19] . . . . .	12
2.4	Pohled na játra zřepředu, převzato z [115] . . . . .	13
2.5	Schéma krevního oběhu jater . . . . .	14
2.6	Anatomie jaterního lalůčku, převzato z [82] a [63] . . . . .	15
2.7	Rozdělení jater při resekci . . . . .	17
2.8	Práce s experimentálním zvířetem . . . . .	18
3.1	Princip CT . . . . .	20
3.2	CT přístroj Siemens Somatom Sensation 64 . . . . .	21
3.3	Vlevo: snímek mozku z výpočetní tomografie z roku 1971 [3]. Vpravo: CT snímek publikovaný v roce 2008 [37] . . . . .	22
3.4	Histogram jater a okolní tkáně. Tkáň jater je značena černou barvou, okolní tkáň je vyznačena šedou barvou . . . . .	24
3.5	Mikro-CT Xradia XCT 400 (NTC ZČU Plzeň). Pravý obrázek znázorňuje uspořádání zdroje záření, detektoru a rotující platformy pro upnutí vzorku . . . . .	24
3.6	Znázornění spinu a precese . . . . .	25
3.7	Zobrazení T1-váženého obrazu a T2-váženého obrazu . . . . .	26
3.8	Znázornění aplikace roviny řezu určujícího gradientu . . . . .	27
4.1	Různé druhy textur . . . . .	29
4.2	Ukázka obrázků a příslušných histogramů . . . . .	31
4.3	Textury se stejným histogramem . . . . .	32
4.4	Směry používané k vytvoření matice sousednosti . . . . .	32

4.5	Výpočet LBP kódu . . . . .	39
4.6	Kruhové okolí LBP s různými parametry . . . . .	40
4.7	Měření texturní linearity, periodicity a velikosti pomocí hran obrazu . . . . .	43
4.8	Voronoi diagram 11 bodů v Eukleidovském prostoru . . . . .	44
4.9	Extrakce příznaků pro segmentaci pomocí Voronoi mozaikování . . . . .	46
4.10	Graf popisující strukturu textury . . . . .	47
4.11	Jednorozměrný AR model . . . . .	47
4.12	Okolí pixelu pro dvojrozměrný odhad . . . . .	48
4.13	Povrchy s různou fraktální dimenzí . . . . .	49
4.14	Filtrování obrazu s různými maskami a vytvoření vícekanálové odezvy banky filtrů . . . . .	51
4.15	Filtry pro analýzu ve frevenční oblasti . . . . .	52
4.16	Transformace obrázku pomocí DFT, DST a DCT . . . . .	54
4.17	Reálná složka jádra Gaborova filtru . . . . .	55
4.18	Odezva Gaborova filtru . . . . .	56
4.19	Dvoustranná texturní analýza . . . . .	56
4.20	Podobnost syntetického texturního obrazu . . . . .	57
4.21	Prahování . . . . .	59
4.22	Optimální prahování pro dva objekty s normálním rozložením . . . . .	59
4.23	Hranování . . . . .	60
4.24	Prahování . . . . .	62
4.25	Průběh segmentace pomocí metody Graph-Cut . . . . .	63
4.26	Princip víceměřítkové segmentace . . . . .	65
5.1	Manuální segmentace pomocí aplikace Syngo Volume . . . . .	68
5.2	Ruční segmentace kombinovaná s prahováním . . . . .	68
5.3	Segmentace jádra kosterní soustavy. To je označeno modrou barvou . . . . .	70
5.4	Projekce kostry . . . . .	71
5.5	Jednotlivé kroky hledání parametrů symetrie . . . . .	72
5.6	Rotace . . . . .	72
5.7	Lokalizace bránice . . . . .	73
5.8	Pohled na výslednou segmentaci bránice . . . . .	74
5.9	Odhad polohy jater na základě polohy významných anatomických struktur. Jednotlivé křivky vyznačují místa se stejnou věrohodností. . . . .	77
5.10	Schema různě velikých voxelů . . . . .	78
5.11	Konstrukce hran grafu typu N-links . . . . .	79
5.12	Váhy typu T-link pro popředí ( $R_p^O$ ) a pozadí ( $R_p^B$ ) . . . . .	81
5.13	Váhy typu N-link ( $B_p$ ) pro horizontální a vertikální směr . . . . .	82
5.14	Ukázka popisu prostřednictvím dvoustranného filtru . . . . .	82
5.15	Ukázka tvarového model parenchymu jater . . . . .	85
6.1	Řez segmentovanými daty se znázorněním skeletonu . . . . .	87
6.2	Ukázka komplikovaných situací při tvorbě skeletonu . . . . .	88

6.3	Ukázka modelu cévního řečiště. Vlevo jednoduchá reprezentace, vpravo reprezentace s modelovanými spoji . . . . .	88
6.4	Vizualizace cévní mikrostruktury pomocí LAR . . . . .	89
6.5	Schéma víceměřítkového numerického modelu perfuze jaterního parenchymu . . . . .	91
6.6	Ilustrace cévních segmentů, převzato z [129] . . . . .	92
6.7	Perfuzní rychlosti ve filtračním systému, viz [8] . . . . .	93
6.8	Časový vývoj distribuce kontrastní látky. Nahoře je vizualizace filtračního systému, dole je zobrazena koncentrace v transverzálním řezu . . . . .	94
6.9	Příprava korozivního preparátu, pravý obrázek převzat z [34] . . . . .	95
6.10	Korozivní preparát jaterních cév prasete . . . . .	96
6.11	Oddělení vzorku od korozivního preparátu celých jater. Vlevo pila Proxxon Micro Band Saw 240-E, vpravo pak oddělený vzorek. Viz [34] . . . . .	96
6.12	Vzorek Micro CT řezů korozivního preparátu jaterních cév s rozlišením $0.004682 \times 0.004682 \times 0.004682$ [mm] a velikostí $992 \times 1013$ . . . . .	97
6.13	Porovnání snímků z běžné výpočetní tomografie a mikro-CT. Vlevo snímky z přístroje Siemens Somatom Sensation 64, vpravo snímky z Xradia XCT 400 . . . . .	98
6.14	Záchyt objektů v uvnitř disektoru . . . . .	100
6.15	Objemová sonda „Unbiased Brick“, obrázek převzat a upraven z [39] . . . . .	100
6.16	Měření délky. a) délka daná dvěma voxely b,c) větší délky měřené různými způsoby: 1) pixel to pixel 2) proložení polynomiální křivkou . . . . .	101
6.17	Sonda protíná 3D objekt, převzato z [68] . . . . .	103
7.1	Ukázka řezů játry v jednotlivých trojrozměrných snímcích z databáze SLIVER'07. Zelenou barvou je naznačena segmentace jater . . . . .	105
7.2	Obrázky dokumentují statistické rozložení velikosti voxelu a velikosti jednotlivých obrázků v datasetu SLIVER'07 . . . . .	106
7.3	Ukázka datasetu 3D-IRCADb-01 . . . . .	106
7.4	Závislost velikosti pracovního voxelu na úspěšnosti segmentace . . . . .	107
7.5	Závislost parametru $\alpha$ na úspěšnosti segmentace . . . . .	107
7.6	Závislost počtu komponent v intenzitním modelu popředí a pozadí na úspěšnosti segmentace . . . . .	108
7.7	Závislost úspěšnosti segmentace na apriorním zvětšení objemu . . . . .	108
7.8	Závislost počtu iterací MorphACWE na úspěšnosti segmentace . . . . .	109
7.9	Závislost parametru $\lambda_1$ MorphACWE na úspěšnosti segmentace . . . . .	109
7.10	Porovnání měření objemu různými metodami . . . . .	111
7.11	Ukázka řezů jedním trojrozměrných testovacích obrazů . . . . .	112
7.12	Porovnání doby výpočtu přímé metody Graph-Cut (Graph-Cut a víceměřítkové segmentace (MSGC) . . . . .	113
7.13	Celkový počet hran v grafu při výpočtu segmentace prostřednictvím GC a MSGC. Velikost objektu je fixována . . . . .	114
7.14	Doba výpočtu řezu grafu a celková doba výpočtu pro metody GC a MSGC	114
7.15	Znázornění celkové délky výpočtu pro metody Graph-Cut a MSGC . . . . .	116

7.16	Ukázka textur použitých pro testování TSGFGC . . . . .	117
7.17	Ukázka segmentace. Vlevo metoda TSGFGC, vpravo GFGC. . . . .	118
7.18	Ukázka segmentace pomocí texturního popisu. Příznakový vektor je tvořen z histogramu, klasifikátorem je Decision Tree . . . . .	118
7.19	Výsledky segmentace pomocí texturní analýzy . . . . .	119
7.20	Výsledky segmentace pomocí texturní analýzy - objemová chyba (VD) .	120
7.21	Porovnání rozložení výsledků manuálního kvantitativního měření s automatickým . . . . .	122
8.1	Segmentace modulem <i>pysegbase</i> . . . . .	125
8.2	Aplikace Lisa . . . . .	126
8.3	Ukázka rozhraní aplikace QuantAn . . . . .	127

# Seznam tabulek

3.1	Denzity některých typů tkání v Hounsfieldových jednotkách . . . . .	22
3.2	Okénka pro pozorování různých tkání . . . . .	22
3.3	Intenzity signálu MR některých tkání . . . . .	27
4.1	Hodnoty entropie a třetího a čtvrtého momenty pro data z obrázku 4.2 .	31
4.2	Hodnoty některých příznaků pro textury z obrázku 4.3 . . . . .	34
4.3	Váhy jednotlivých typů hran při konstrukci grafu pro segmentaci pomocí Grap-Cut . . . . .	64
7.1	Statistické informace o datasetu Segmentation of the Liver 2007 (SLI- VER'07), rozměry obrazového bodu jsou uvedeny v milimetrech, rozměry v rovině řezu ( $xy$ ) a ose řezu ( $z$ ) jsou uvedeny v počtu obrazových bodů [ $px$ ] . . . . .	105
7.2	Měření reálného objemu . . . . .	110
7.3	Srovnání měření objemu lahve pomocí Syngo Volume . . . . .	111
7.4	Souhrn informací o délce výpočtu segmentace na celém datasetu pro- střednictvím metod Graph-Cut a MSGC . . . . .	113
7.5	Souhrn informací o délce výpočtu segmentace na vybrané části datasetu prostřednictvím metod Graph-Cut a MSGC . . . . .	115
7.6	Srovnání výsledků různých segmentačních metod . . . . .	116
7.7	Hodnocení průměrů vybraných metrik pro segmentaci pomocí texturních příznaků . . . . .	120
7.8	Wilcoxonův test . . . . .	121
7.9	Spearmanův koeficient pořadové korelace . . . . .	122
10.1	Měření histologických parametrů prostřednictvím automatické a manu- ální metody s poloměrem uzlu 0,012 mm . . . . .	147
10.2	Měření histologických parametrů prostřednictvím automatické a manu- ální metody s poloměrem uzlu 0,015 mm . . . . .	148
10.3	Měření histologických parametrů prostřednictvím automatické a manu- ální metody s poloměrem uzlu 0,018 mm . . . . .	149



# Zkratky

**ACM** Active Contour Model.

**AR** Autoregressive.

**ARMA** Autoregressive Moving Average.

**BH** Body Height.

**BSA** Body Surface Area.

**BW** Body Weight.

**CBCT** Cone Beam Computed Tomography.

**CSV** Comma-separated values.

**CT** Computed Tomography.

**CT** Computed Tomography.

**CUReT** Columbia-Utrecht Reflectance and Texture Database.

**DCT** Discrete Cosine Transform.

**DFT** Discrete Fourier Transform.

**DICOM** Digital Imaging and Communications in Medicine.

**DST** Discrete Sine Transform.

**DT** Decision Trees.

**EM** Expectation Maximization.

**FAV** Fakulta Aplikovaných Věd.

**GC** Graph-Cut.

**GFGC** Gabor Filer Graph-Cut segmentation.

**TSGFGC** Two-sided Gabor Filer Graph-Cut segmentation.

**GLCM** Gray Level Coocurance matrix.

**HU** Hounsfield Unit.

**KLT** Krahunen-Loeve Transform.

**LBP** Local Binary Patterns.

**LDA** Linear Discriminant Analysis.

**LoG** Laplacian of Gaussian.

**LV** Liver Volume.

**MA** Moving Average.

**MICCAI** Medical Image Computing and Computer Assisted Intervention.

**MRI** Magnetic Resonance Imaging.

**MRI** Magnetic Resonance Imaging.

**MSCT** Multi Slice Computed Tomography.

**MSGC** Multi-Scale Graph-Cut.

**NTC** Nové technologie - výzkumné centrum.

**NTIS** Nové technologie pro informační společnost.

**OCR** Optical Character Recognition.

**PyPI** Python Package Index.

**QDA** Quadratic Discriminant Analysis.

**SLIVER'07** Segmentation of the Liver 2007.

**SVM** Support Vector Machine.

**USG** Ultrasonography.

**VD** Volume Differece.

**YAML** YAML Ain't Markup Language.

# Slovník

**denzita** Míra oslabení záření v jednotlivých místech vyšetřovaného objektu (prostřednictvím CT). Měřena je v Hounsfieldových jednotkách HU [86].

**parenchym** Parenchymem se rozumí funkční tkáň, která je specifická pro každý orgán..

**perfuze** Průtok krve či jiné tekutiny tkání, případně jiným prostředím.

**ventralis** Směr přední, směrem k břišní straně.

**voxel** Objemový element, který je třídimenzionální analogií k pixelu. Jedná se o složeninu anglických slov *volumetric* a *element*.

# 1

## Úvod

Vidění umožňuje živočichům vnímat prostřednictvím světla a barev svět, kterým jsou obklopeni. Pro člověka má zrak mimořádný význam, neboť jím vnímá asi 80% veškerých informací. Díky tomu je schopnost vidět, zpracovávat a interpretovat viděné považována lidmi za samozřejmou. Rozšíření možností strojů o schopnost vidět (nazývané počítačové vidění, nebo strojové vnímání) se z tohoto důvodu nepoučenému člověku může zdát samozřejmé a snadno řešitelné. Pravý opak je však pravdou. Geny pro vnímání světla se objevily u nezmarů před 600 miliony let ([95]). Evoluce oka i následného zpracování zrakových vjemů probíhala velmi dlouhou dobu, zatímco zkoumání metod počítačového vidění probíhá intenzivně až v posledních třiceti letech a je tedy co dohánět.

Základy dnešního oboru počítačového vidění je možné hledat v oboru zpracování signálů, ze kterého vychází oblast zpracování obrazu. S obrazem se v ní pracuje jako s dvojrozměrným (nebo vícerozměrným) signálem. V řešených úlohách nejde o interpretaci scény, která je zachycena v obraze, ale například o zlepšení kvality obrazu, odstranění nežádoucích poruch v obraze a tak dále. Návazným oborem je analýza obrazu, která se snaží obraz částečně interpretovat. Pracuje se zpravidla s dvojrozměrnými daty. Dobrým příkladem může být počítání buněk v obraze z mikroskopu ([73]). Analýza obrazu postupně přerůstá v počítačové vidění. To řeší problémy nejobecněji, zabývá se problematikou trojrozměrného světa a počítá se sekvencemi obrazu v čase.

Výzkum v oblasti počítačového vidění je zaměřen na kopírování a napodobování principů, které jsou využívány v přírodě. Aplikace využívající tohoto výzkumu často řeší úlohy, v nichž bez obtíží obstojí i člověk. Jejich cílem je úspora času lidské obsluhy. Příkladem takových úloh může být výstupní kontrola kvality na výrobní lince nebo optické rozpoznání textu – Optical Character Recognition (OCR). Uplatnění takových řešení je pak nacházeno v nejrůznějších oblastech lidské činnosti, kde šetří lidskou práci.

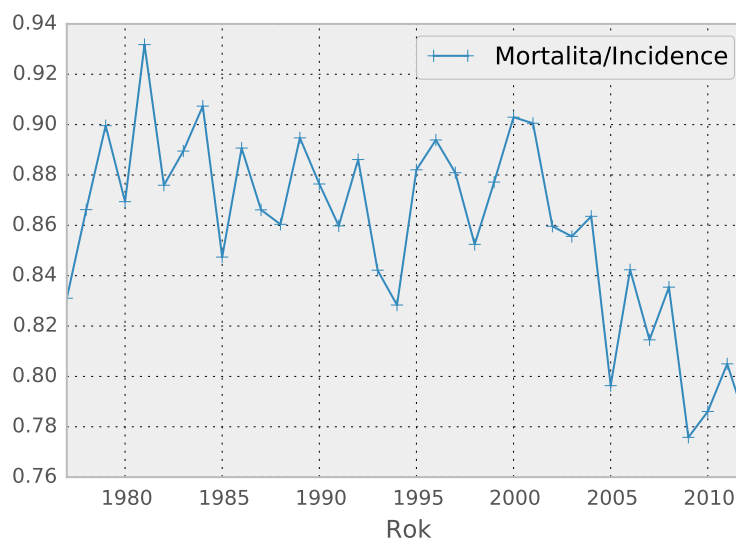
Kromě těchto úloh jsou řešeny i problémy, ve kterých stroje svými výsledky hravě překonávají člověka. Často nejde jen o rychlost a přesnost řešení, ale vůbec o schopnost dobrat se výsledku. Mezi takové úlohy patří nejrůznější trojrozměrné rekonstrukce prostoru atd.

Jedním z odvětví lidské činnosti, ve kterém v posledních letech aplikace strojového nabývají na významu, je medicína. Využívány jsou v řadě různých úloh, ve kterých

---

usnadňují práci lidí v oblasti péče o zdraví, ale i ve výzkumu. Významným tématem, na které je orientován pohled medicínského zkoumání je porozumění dějů v parenchymatózních orgánech břišní dutiny. Mezi ty se řadí ledviny, játra a slezina. Parenchymem se rozumí funkční tkáň, která je specifická pro každý orgán. Například jaterní parenchym je tvořen jaterními buňkami (hepatocyt).

Očekávatelným důsledkem detailního pochopení funkce těchto orgánů, které je umožněno rozvojem techniky, je zdokonalení léčebných procedur a zejména pak léčba nádorových onemocnění. V případě sleziny nejsou nádorová postižení příliš obvyklá. Onkologická postižení ledvin a jater je situace významně jiná.

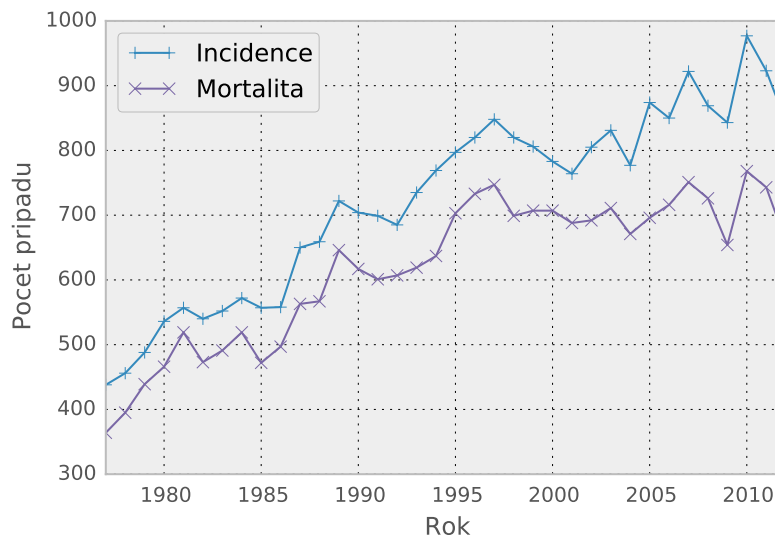


**Obrázek 1.1:** Incidence a mortalita zhoubných nádorů jater a žlučovodů na území ČR, zdroj: [32], zdroj primárních dat: [1]

Celosvětově patří nádory jater k nejrozšířenějším zhoubným onemocněním. Mezi nejpostiženější patří oblasti jako subsaharská Afrika, jižní a jihovýchodní Asie a Čína. Rozvojové země představují až 81% celkového světového výskytu. Čínská populace pak představuje 50 % celosvětové mortality. V České republice není výskyt naštěstí tak častý. Obrázek 1.1 zobrazuje závislost mezi počtem každoročně odhalených případů (incidence) zhoubného nádoru jater a počtem úmrtí (mortalita) s touto diagnózou souvisejících. Z grafu je patrné, že trend v posledních letech klesá. Absolutní počet obětí však v čase roste, jak dokumentuje obrázek 1.2, kde je zobrazen časový průběh absolutní incidence a mortality.

Mezi primárními nádory jater se nejčastěji objevuje hepatocelulární karcinom. Ten tvoří až 90 % celkové epidemiologické zátěže [33].

Častým problémem jater jsou metastatické postižení z jiné primární lokalizace. Nejvýznamnějším přispěvatelem je kolorektální karcinom. Ve spojených státech amerických byla v roce 2014 tato diagnóza indikována 136830 pacientům ([109]). V celosvětovém



**Obrázek 1.2:** Počet případů zhoubných nádorů jater a žlučových, zdroj: [32], zdroj primárních dat: [1]

žebříčku jeho incidence zaujímá Česká republika pravidelně jedno z prvních pěti míst [32].

Klíčovým prvkem v porozumění dějům uvnitř jater je cévní zásobení tohoto orgánu. To je vědecky intenzivně studováno, avšak řada otázek zůstává stále otevřená. Problematické je zejména zkoumání dějů v jaterním lalůčku. V jeho rámci se odehrává podstatná část procesů, které jsou pro náš život podstatné. Cévní zásobení této jednotky je zprostředkováno cévami malých rozměrů, které je obtížné zachytit běžnými klinickými zobrazovacími metodami.

Pracoviště Lékařské fakulty v Plzni Univerzity Karlovy v Praze ve spolupráci s Fakultní nemocnicí se dlouhodobě této problematice věnuje. Partnerem v řešení technických otázek výzkumných projektů je mu řada pracovišť Fakulty aplikovaných věd v Plzni, výzkumná centra NTIS a NTC.

## 1.1 Cíle práce

Vývoj nových léčebných metod zpravidla vyžaduje detailní pochopení jednotlivých funkčních celků lidského organismu. Léčba parenchymatózních orgánů nepředstavuje výjimku. Obecným cílem této práce je tedy vytvoření nástrojů a metod rozvíjející proces poznávání funkce těchto tkání.

Pro detailní pochopení funkce parenchymů je podstatným prvkem porozumění proudění krve uvnitř tkáně. Proces prokrvení bývá nazýván perfuzním dějem. Vytvoření popisu tohoto procesu s využitím klinických dat a zvířecího modelu je základním předpokladem pro příští výzkum.

Cévní systém parenchymů zahrnuje cévy o široké škále průsvitů. U jater je má vstupní portální žíla průměr přes 10mm (11,5 mm u 107 pacientů mezi 21-40 lety, viz [130]). Nejmenější cévy, sinusoidy, pak mají méně než 0,01 mm. Zachytit geometrii ve všech měřítkách s využitím rozličných zobrazovacích metod představuje náročnou výzvu. V této práci si klademe za vytvořit metoda, která na základě rozličných zdrojů umožní poskytnout podklady pro modelování prokrvení parenchymů.

- Modelování proudění v parenchymu vyžaduje informaci o geometrii parenchymu, ale i geometrii cévního systému. Důležité jsou informace o průsvitech jednotlivých cév, ale také potlačení šumu, který vzniká v důsledku snímání zobrazovacími technikami. Cílem je tedy navržení metody popisu parenchymatózních orgánů a jeho cévní struktury s ohledem na modelování průtoků krve.
- Vytvoření představy o prostorovém uspořádání parenchymu musí vycházet z hodnověrných datových podkladů. Takový zdroj dat představují trojrozměrné zobrazovací metody. Vymezení objemu parenchymu však není samozřejmou záležitostí. Škála intenzit, která je zobrazována uvnitř těchto orgánů, je zaměnitelná s řadou dalších tkání. Navržení metody pro segmentaci trojrozměrných dat využívající vhodnou interakci tak představuje další cíl této práce.
- Model prokrvení parenchymu vyžaduje kromě znalosti tvaru parenchymu i představu o uspořádání cévního systému. Stejně jako u vymezení objemu parenchymu, i zde platí, že vše vychází z kvality vstupních dat. Ta je do značné míry omezená a nestálá. V obvykle používaných zobrazovacích metodách bývá céva zvýrazněna využitím kontrastní látky. Intenzita jejího zobrazení je pak zpravidla závislá na koncentraci aplikované kontrastní látky, čase uplynulém od okamžiku podání, individuálních parametrech oběhového systému zkoumaného pacienta, či experimentálního zvířete, a na mnoha dalších nezbadatelných proměnných.

Cílem této práce je vytvoření metody pro tvorbu geometrického modelu cévního řečiště parenchymatózních orgánů, který bude vhodný pro modelování prokrvení.

- Současné klinické zobrazovací metody jsou schopny zachytit cévy do průměru kolem jednoho milimetru. Tyto techniky neumožňují detailnější zobrazení mikrostruktur, které jsou pro pochopení dějů v parenchymech důležité. Modelování prokrvení parenchymů na základě těchto dat přinese určitý stupeň poznání. Naším plánem je však dále tyto možnosti rozšířit prostřednictvím využívání zvířecích modelů. Cílem této práce je pak vytvořit metodu zpracování obrazových dat, která zachycují mikrovaskulaturu parenchymu, za účelem vytvoření podkladů pro modelování prokrvení.

## 1.2 Struktura textu

Text této práce je rozdělen do několika částí. Po úvodu následuje kapitola 2. Ta otevírá medicínské pozadí této práce a věnuje se anatomickému a funkčnímu popisu parenchymatózních orgánů. Jejím cílem je seznámit čtenáře se základními stavebními prvky

těchto tkání a s procesy proudění, které v nich probíhají. Část 3 vysvětluje trojrozměrné zobrazovací techniky, které se týkají naší problematiky. Na popis metod pro získání potřebných obrazových dat navazuje část 4 popisem metod počítačového vidění pro trojrozměrné obrazy a zakončuje tím část práce, která má za úkol seznámit čtenáře se stavem současného poznání.

Kapitola 5.1 obsahuje tvorbu tvarového popisu parenchymů. Část statě je věnována praktickému kontextu a dopadům, které jsou využitelné v klinické praxi. Je například představena metoda pro dvoustrannou texturní analýzu a metoda pro víceměřítkovou segmentaci. Text práce tak vstoupil do části, která obsahuje řešení úkolů stanovených v úvodu a popisuje přínosy práce. Kapitola 6 je orientována na studium struktury cévního řečiště. Je zde popsána metoda tvorby modelu cévního stromu. Jsou zde rozvíjeny prostředky umožňující modelování proudění. Část 6.3 se pak věnuje analýze mikrovaskulatur.

Kapitola 7 ověřuje prostřednictvím experimentů myšlenky představené v částech 5.1 a 6. Jsou zde shrnuty výsledky experimentů provedených při vytváření tvarového modelu perfuze jaterního parenchymu. Dále jsou zde srovnány výsledky manuálního a poloautomatické evaluace dat na základě histologických metrik, ale i další experimenty. Kapitola obsahuje diskuzi k provádění jednotlivých procedur. V části 8 jsou shrnuty aplikace, které vycházejí z navržených metod. Je zde poukázáno na několik modulů pro jazyk Python, které byly souběžně s touto prací vytvořeny a které jsou nachystány pro další používání.

Vyhodnocení práce je provedeno v kapitole 9. V textu jsou zhodnoceny dosažené výsledky a hlavní přínosy práce. Na závěr jsou připojeny plány dalšího výzkumu.



## 2

# Parenchymatozní orgány břišní dutiny

Parenchym je vlastní funkční tkáň některých orgánů, které je pro daný orgán specifická. Například jaterní parenchym je tvořen jaterními buňkami. Opakem parenchymu je podpůrná vazivová tkáň. Mezi parenchymatozní orgány patří játra, slezina a ledviny. Podrobnosti o anatomii a funkci jsou čerpány z [20], [19] a [86].

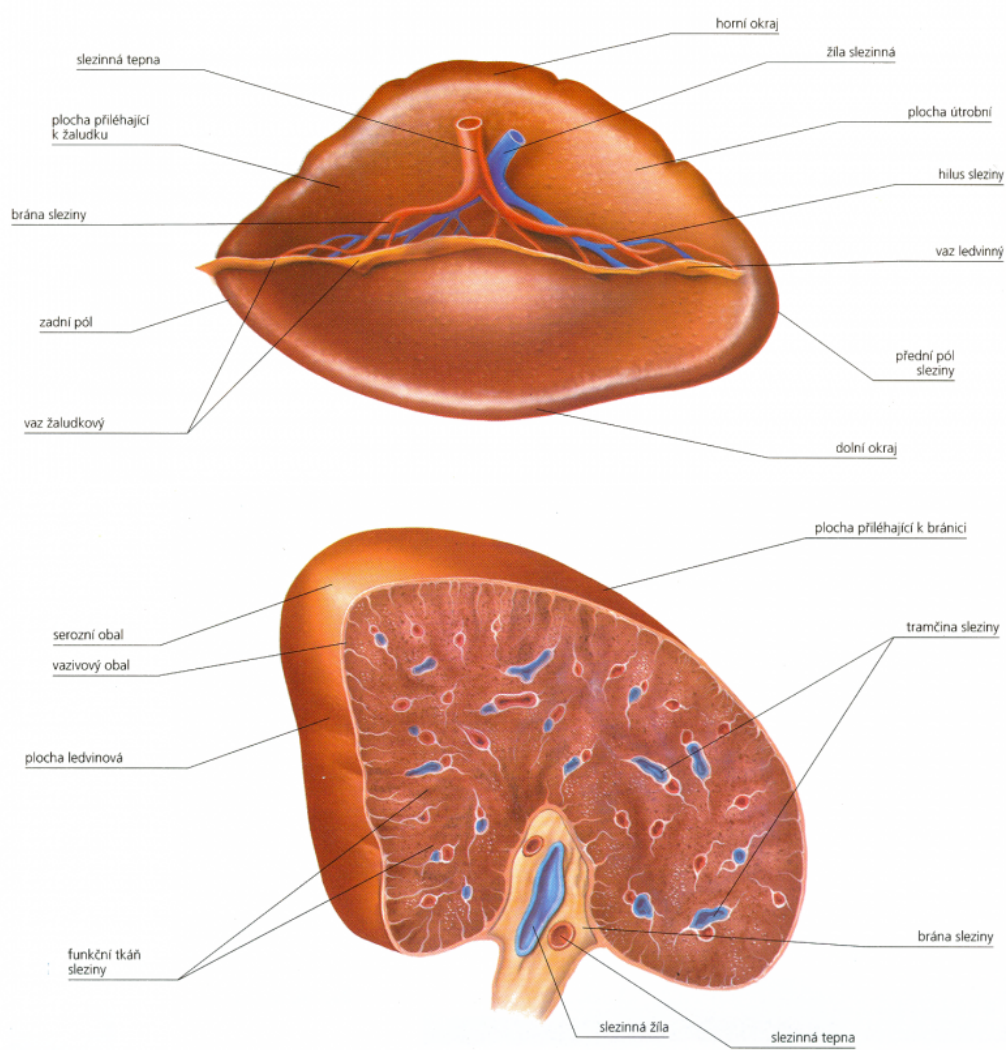
## 2.1 Slezina

Jak píše Čihák [20], slezina je uložena v levé klenbě brániční - v pars supramesocolica, v prostoru označovaném jako saccus splenicus. Její šíře sahá od 9. do 11. žebra, její podélná osa sleduje 10. žebro nebo 10. mezižebří. Je uložena šikmo zezadu shora dopředu dolů a je zakřivena podle brániční klenby.

V orgánu jsou vycytávány a destruovány opotřebované červené krvinky a jsou zde tvořeny lymfocyty. Jedná se o největší lymfatický orgán zařazený do krevní cirkulace. Jedná se o významné místo obrany proti škodlivinám a infekcím, které vnikají do cirkulace. Tato obrana probíhá produkcí protilátek, imunokompetentních buněk a také fagocytárními schopnostmi buněk. Dále slezina slouží jako rezervní krevní nádrž. Krev je ze sleziny vypuzena při zvýšené potřebě kyslíku. Ve fetálním období se ve slezině normálně objevuje krvetvorba, která po vytvoření funkční kostní dřeně ustává.

Hmotnost sleziny je závislá na míře naplnění krví. Slezina je větší v klidu. Při usilovné práci je z ní krev vypuzována. U mužů se uvádí 140 – 160 gramů, u žen je to 120 – 150 gramů. Slezina je křehká, při tupých nárazech na břišní stěnu se snadno trhá.

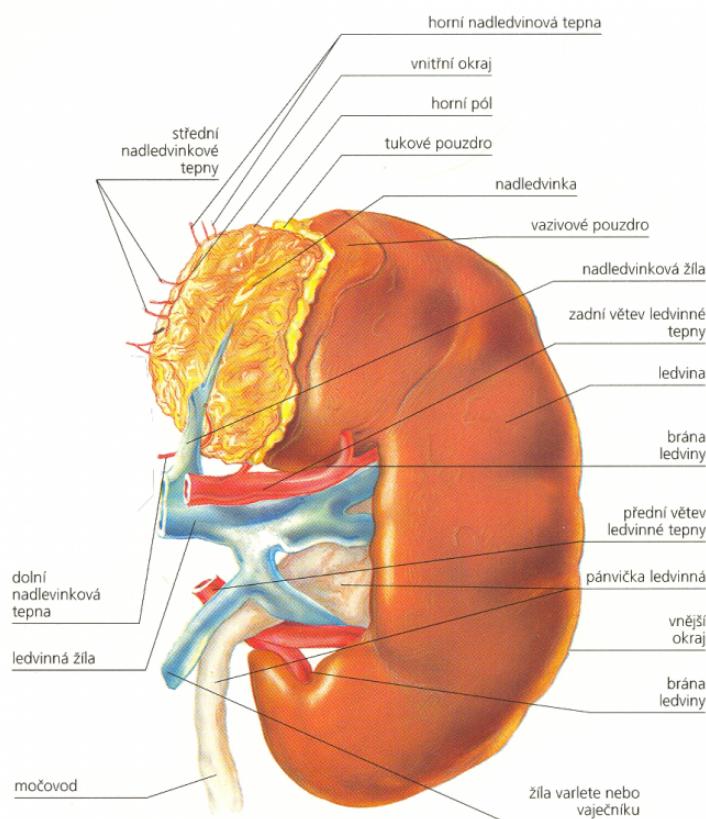
Informace o vyšetřování sleziny zobrazovacími metodami jsou popsány v [86]. Základní zobrazovací metodou používanou pro vyšetření sleziny je sonografie. Normálně má na Ultrasonography (USG) homogenní echogenitu. V případě potřeby upřesnění nálezu je indikováno Computed Tomography (CT). Dodatečné zobrazovací metody jsou používány výjimečně.



Obrázek 2.1: Slezina, převzato z [115]

## 2.2 Ledviny

Podle [19] je základní funkcí ledvin exkrece moče, v níž odcházejí produkty metabolismu. Převažuje v nich produkt přeměny bílkovin – močovina. Vylučováním močoviny, solí a přebytku vody pomáhají ledviny udržovat vnitřní prostředí organismu. Mají též funkce endokrinní. Produkují a do krve uvolňují renin, který ovlivňuje krevní tlak, erythropoetin, který ovlivňuje tvorbu červených krvinek, a 1,2-hydroxycholecalciferol, zapojený do regulace metabolismu vápníku.



**Obrázek 2.2:** Ledvina, převzato z [115]


Ledvina je dlouhá asi 10–12 cm, široká 5–6 cm. Tvar ledviny se nejčastěji přirovnává k fazolovému bobu. Tomu odpovídá tvarem obvodu i předozadním zploštěním. Hmotnost ledviny je 120–170 g. Velikost ledviny se během života mění. Maxima dosahuje kolem 28–30 roku života. Obrázek 2.2 zobrazuje ledvinu a popisuje některé její části.

Nejčastěji indikovanou vyšetřovací metodou močového traktu je ultrasonografie ([86]). Její výhodou je neinvazivnost a vysoká vypovídací schopnost. Hojně uplatňované jsou rovněž endoskopické metody. Stále méně využívaná je angiografie. Výpočetní tomografie je v praxi využívána až po USG. Podává dobrou prostorovou představu

o retroperitoneálním prostoru. Pro kvalitně provedené vyšetření je důležitá správná příprava. Jedná se o perorální podání kontrastních látek 2–3 hodiny před zahájením vyšetření. Pro kvalitní vyšetření je rovněž nezbytné podání kontrastní látky intravenózně.

## 2.3 Játra


Jak je psáno v [19], orgán je umístěn těsně pod bránicí. Z větší části pod pravou brániční klenbou, přesahuje však až pod mediální část levé brániční klenby. Od levého laloku dále doleva je v levé klenbě ještě žaludek a slezina. Umístění v břišní dutině ilustruje obrázek 2.3



**Obrázek 2.3:** Poloha jater v břišní dutině, AX - řez v pravé přední axiální čáře, P.dx. řez v pravé parasternální čáře, P.sin. řez v levé parasternální čáře, C – tlusté střevo (colon), D – dvanáctník (duodenum), G – žaludek (gaster), K – vyústění jícnu do žaludku (cardia), P – slinivka (pancreas), R – ledvina (ren), převzato z [19]

Játra jsou největším vnitřním orgánem našeho těla. Orgánem, který je nezbytný pro náš život. Protéká jimi asi 1500 ml krve za minutu [121]. Jejich objem se pohybuje

kolem 1100 ml. V článku [127] byla na vzorku 31 pacientů naměřena střední hodnota objemu jater 1225 ml pro muže a 1057 pro ženy. Hmotnost jater je uváděna v rozmezí od 1,4 kg – 1,8 kg u mužů a 1,2 kg – 1,4 kg u žen. U dospělého člověka představují játra asi 2,8 % hmotnosti těla. U novorozence je tento poměr asi 4 %.



Obrázek 2.4: Pohled na játra zepředu, převzato z [115]

### 2.3.1 Funkce jater


Funkce jater je mnohočetná, mezi základní poslání jater patří produkce žluči, močoviny a detoxifikační funkce. Díky vysoké metabolické aktivitě jater se jedná o orgán produkující významné množství tepla. Slouží pro stabilizaci hladiny glukózy, kterou dokáží v případě potřeby zachytávat v portální krvi. Tyto nejvýraznější funkce jater lze doplnit ještě o další.

Na některé toxické látky je jaterní tkáň velmi citlivá. Jde například o alkoholickou cirhózu. Na druhé straně jsou regenerační schopnosti jater obdivuhodné, zvláště, jedná-li se o tkáň zdravou.

### 2.3.2 Průtok krve játry

Jaterní cirkulace je tvořena dvěma složkami. Funkční složka pracuje s krví, která přivádí látky, které mají být v játrech zpracovány. Tato krev je přiváděna prostřednictvím portální žíly (v. portae). Tato tenkostěnná céva široká asi 15 mm přichází k játrům


v lig. hepatoduodenale, kde je uložena vzadu. Přivádí krev ze všech nepárových orgánů břišní dutiny, tedy ze stěn žaludku, ze střeva, z pankreatu a ze sleziny. V této krvi jsou obsaženy látky vstřebané z potravy a jdoucí do jater ke zpracování. V krvi přichází rovněž krevní barvivo z doživších červených krvinek, které se rozpadají ve slezině.



**Obrázek 2.5:** Schéma krevního oběhu jater

Druhou složkou je složka nutritivní. Ta je přiváděna jaterní tepnou (a. hepatica propria). Do jater přichází v. lig. hepatoduodenale před v. portae, vpředu vlevo. Kyslík přiváděný touto cévou vyživuje žlučové cesty, stěny velkých žil a vazivo. Vzhledem k relativně vysokému obsahu kyslíku ve v. porta se a. hepatica propria podílí na vyživování jaterních buněk jen malou měrou. Její podvázání přesto působí ložiskový zánik jaterní tkáně.

V. portae a a. hepatica propria procházejí játry společně a postupně se větví. Krev obou cév nakonec doputuje k sinusoidám jaterních lalůček (viz obrázek 2.6) a vlije se do nich. Sinusoidy tedy přijímají portální i arteriální krev. V. centralis již patří k odtokovým vv. hepaticae. Postupným spojováním vznikají venae hepaticae, které opouští játra. Jsou zpravidla tři. Dvě z pravého laloku a jedna z levého. Vstupují přímo do v. cava inferior.



Obrázek 2.6: Anatomie jaterního lalůčku, převzato z [82] a [63]

### 2.3.3 Chirurgie jater

Chirurgické zákroky na játrech představují nepříjemný zásah do života každého pacienta. Obvykle však také tyto léčebné metody představují naději, o které se pacienti s řadou diagnóz v dřívějších dobách nemohli ani odvážit uvažovat.

V sedmnáctém a osmnáctém století byly prováděny zákroky na játrech u obětí poranění vzniklých ve válečných vřavách této doby. Prvotní zákroky vedly zpravidla k nekontrolovanému krvácení a následné smrti [5]. V roce 1886 byla provedena první hepatektomie. Po šesti hodinách však došlo k vykrvácení pacienta. První úspěch slavil až o dva roky později (1888) Langenbuch. I zde však došlo k následné operaci, která zastavila krvácení [36].


V období po 2. světové válce bylo publikováno několik prací, které se věnovaly játrům. Claude Couinaud popsal anatomii jater a rozdělil je na osm jaterních laloků [22]. Navzdory mnoha anatomickým poznatkům byla aplikace v klinické praxi značně omezena. Důvodem pro to byl nedostatek metod, které by umožňovaly diagnostikovat menší tumory, jaké by bylo možné operovat. Zlom nastal až v osmdesátých letech, kdy přišla do klinické praxe sonografie. Její zásluhou pak bylo možné začít využívat 30 let staré poznatky z oblasti anatomie. Další rozšíření možností přinesl příchod sonografie na operační sály. Díky tomu bylo možné stanovení resekcční linie s do té doby nevídanou kvalitou.

Léčba prostřednictvím resekcce je v současné době užívána zejména ze dvou důvodů. Prvním je onemocnění rakovinou jater, případně nádor v tomto orgánu. Možnost vyjmout nádor je v takových případech otázkou života a smrti a je dána jeho velikostí a polohou v parenchymu vzhledem k významným cévám. Druhým motivem pro resekcii část jater jsou transplantace od živých (a často příbuzných) dárců - tzv. living related liver transplantation (LRLT). Tyto operace jsou potřebné kvůli nedostatečnému množství vhodných dárců pro transplantace. Je možné je provádět díky velké regenerační schopnosti jater. První LRLT byla provedena v roce 1990 profesorem Strongem v Austrálii [114].

Ze zmíněných důvodů bývá pacientům odebírána část jater. Častým typem operace je anatomická resekcce, při které dochází k odebrání tkáně prokrvované celou jednou větví (či více větvemi) portální žíly, tak aby v těle nezůstala žádná neprokrvená část (viz obrázek 2.7). Volba resekcční linie je pak ovlivněna celou řadou okolností. Umístění jaterních žil má klíčový vliv na odvod krve z jater. Často je tedy linie volena tak, aby tyto cévy zůstávaly v co nejširší míře zachovány. Vliv má umístění ložisek, která musejí být v bezpečné vzdálenosti od resekcční linie. Dále jsou podstatné i další diagnostické parametry.

Alternativním přístupem jsou neanatomické resekcce, které jsou vhodné pro menší ložiska na okraji orgánu. V takových případech lze v rámci chirurgického výkonu část orgánu odstranit bez narušení prokrvování zbytku parenchymu. Mezi další možnosti léčby lze zahrnout radiofrekvenční ablaci. Jedná se o metodu lokální destrukce tkáně, která využívá tepelného účinku procházejícího střídavého proudu o frekvenci v řádu stovek kHz. Výhodou je to, že se koagulují i cévy a tím je zastaveno i krvácení. Zárok je opět vhodný pro menší ložiska do 5 cm.





**Obrázek 2.7:** Rozdělení jater při resekci: LHV - levá jaterní žíla, LPV - levá větev portální žíly, LHA levá větev jaterní tepny, převzato z [114]

Před jakýmkoliv zákrokem musí být provedena diagnostika pacienta s širokým zaměřením. Důležitým parametrem je odhad velikosti zbytkové části parenchymu, která má klíčový význam pro zachování funkce orgánu a život pacienta. Často pomáhá určit, jaký chirurgický zákrok bude pro mít pro pacienta nejlepší léčebný dopad, či zda by nebyla vhodná některá z dalších onkologických metod.

## 2.4 Spolupráce s Fakultní nemocnicí v Plzni

Fakulta aplikovaných věd dlouhodobě spolupracuje s odborníky z Lékařské fakulty Univerzity Karlovy v Plzni. Aktivní spolupráce probíhá mezi odborníky z oborů chirurgie, radiologie, experimentální medicíny (viz obrázek 2.8), histologie a řady dalších přidružených pracovišť. Společný vědecký program je orientován na studium jater a rozvíjení pokročilých diagnostických procesů s ohledem na léčbu tohoto orgánu.

Spolupráce je zaměřena na rozvoj výuky experimentální chirurgie na LF v Plzni a biomechaniky na ZČU v Plzni s důrazem na seznámení se s moderními medicínskými a experimentálními technologiemi. Cílem projektu je vytvořit edukační program pro výuku experimentální a klinické chirurgie a biomechaniky s implementací nových postupů a znalostí, který by odpovídal současným nejnovějším znalostem z oboru experimentální medicína a z oborů hraničních.

Cílem projektu je především etablovat softwarové modelování, které je dlouhodobě rozvíjeno v rámci spolupráce Fakulta Aplikovaných Věd (FAV) a NTC ZČU s LFP UK v rámci experimentální CT laboratoře.

V rámci dalšího rozvoje spolupráce ZČU a FN v Plzni předpokládáme rozvíjet softwarového modelování takovým směrem, aby určitým způsobem doplnilo, a v některých

## 2.4 Spolupráce s Fakultní nemocnicí v Plzni

---



**Obrázek 2.8:** Práce s experimentálním zvířetem

oborech i přímo nahradilo, experimentální práci na animálních experimentálních modelech. Tyto výsledky budou dále rozvíjeny v rámci dalších aktivit pro klinické aplikace, např. virtuální modely proudění krve v cévách.

V dalším textu budou rozvíjeny metody, které jsou platné (s určitými výjimkami) pro všechny výše zmíněné parenchymatózní orgány. Vzhledem ke zmíněné spolupráci je však kladen důraz právě na práci s játry.

## 3

# Trojrozměrné zobrazovací metody a modelování proudění

Lékařská věda prochází, stejně jako ostatní vědní obory, bouřlivým vývojem. Jedním z významných mezníků pro lékařskou diagnostiku byl objev Röntgenových paprsků ([101]). Za něj byla v roce 1901 udělena první Nobelova cena za fyziku. Díky tomuto objevu je možné provádět diagnostiku relativně neinvazivním způsobem. Od prvního desetiletí 20. století dochází k rozvoji radiologie jako medicínského oboru. Díky technickému pokroku se obor diagnostiky pomocí rentgenového záření rozšířil o ultrasonografii a magnetickou rezonanci. Významným okamžikem bylo vyvinutí výpočetní tomografie ([86]).


Radiologické metody využívají rentgenové záření nebo ionizující záření uzavřených zářičů. Postupem času byly včleněny i další principy, využívající ultrazvukové vlnění (sonografie) a elektromagnetické záření (magnetická rezonance). Oborem, který vyžívá k diagnostice (ale i terapii) otevřené zářiče, je nukleární medicína. Pacientovi je podána kontrastní látka obsahující radioizotop a pomocí vyšetření je sledována koncentrace označené látky v různých částech těla. Užitečnost metod spočívá zejména ve zobrazení funkcí. Na zobrazení anatomických detailů se metody nukleární medicíny příliš nehodí, zejména kvůli malému prostorovému rozlišení.

V poslední době roste význam výpočetní tomografie (CT) a magnetické rezonance (Magnetic Resonance Imaging (MRI)) jako dostupné vyšetřovací techniky s nízkou zátěží pacienta. Výpočetní tomografie je vhodná na zobrazování kostí, magnetická rezonance se hodí lépe na měkké tkáně. Vhodnou kombinací obou je možné pokrýt široké spektrum diagnostických úloh. Společnou vlastností obou modalit je výstup ve formě trojrozměrných dat. Rozšíření těchto vyšetřovacích metod je důvodem pro zaměření tohoto textu právě na ně. Dalším důvodem pro cílený výzkum těchto modalit je jejich používání v klinické praxi. Pro diagnostiku parenchymů jsou používány i Klinikou zobrazovacích metod při fakultní nemocnici v Plzni, se kterou dlouhodobě spolupracujeme.

### 3.1 Výpočetní tomografie

Historie výpočetní tomografie (CT) sahá do druhé poloviny šedesátých let, kdy byla zpracována analytická metoda, umožňující rekonstruovat výpočtem ze superprojekce matic rotujícího vektorového prostoru rovinnou skalární maticí. Konstrukce prvního tomografu byla umožněna použitím dostatečně výkonné výpočetní techniky. Myšlenka medicínsky využitelné tomografické metody vychází od Alana MacCormicka. První tomograf sestrojil Geoffrey Hounsfield v roce 1971. Produkoval matici  $80 \times 80$  bodů a zobrazení se provádělo v řádu jednotek minut. Postupným vývojem došlo ke zkrácení akvizičních časů (čas snímání jednoho řezu) a zvýšení rozlišovací schopnosti. V roce 1978 byla oběma mužům udělena Nobelova cena za převratný objev ([38]).

K získání tomografického řezu využívají CT přístroje koordinovaného pohybu rentgenky a detektoru záření, které se pohybují kolem vyšetřované tělesné oblasti. Princip pohybu znázorňuje obrázek 3.1. Tím je zajištěno vytvoření jednoho řezu snímku. Navýšením počtu snímačů lze snímat více řezů na jeden oběh rentgenky. Tato konstrukce je nazývána vícesnímkové CT - Multi Slice Computed Tomography (MSCT) Podrobnosti o takových přístrojích lze načerpat v [85] a [126]. Narozdíl od sumačních snímků, na



**Obrázek 3.1:** Princip CT. Pro zhotovení jedné vrstvy se systém rentgenka(R) a detektoru(D) otočí kolem pacienta (P). Prošlé záření je registrováno detektory a počítačově zpracováváno. Převzato z [86]

kterých se překrývají jednotlivé orgány a tkáňové struktury, jimiž záření prošlo, podává CT vrstvý obraz.

Snímaná data jednoho řezu jsou výsledkem Radonovy transformace. Pro rekonstrukci lze teoreticky použít zpětnou Radonovu transformaci, z důvodu stability je však

### 3.1 Výpočetní tomografie

v praxi využíván algoritmus filtrované zpětné projekce. Výsledný řez nevyšetřuje plochu, ale objem. Vrstva má určitou tloušťku a obraz je složen z kvádrů - voxelů (volume matrix element).



Obrázek 3.2: CT přístroj Siemens Somatom Sensation 64


U současných přístrojů je velikost výstupní matice nejčastěji  $512 \times 512$  voxelů, u některých přístrojů může být i  $1024 \times 1024$ . Rozlišovací schopnost CT (0.5-1 pár čar na milimetr) je dána velikostí zobrazovaného pole a maticí. Oproti analogovému vyšetření (5-8 párů čar na milimetr) je omezená. Konkrétně například přístroj Siemens Somatom Sensation 64, který je na obrázku 3.2, má izotropní prostorové rozlišení 0.24 mm. Běžně jsou s ním vytvářeny snímky řezu s rozlišením 1 mm a silou řezu 0.6 mm.

Síla výpočetní tomografie však není dána prostorovou rozlišovací schopností, ale rozlišením kontrastů. Díky přesnému určení denzity (absorbční schopnosti) tkáně má výpočetní tomografie převahu nad analogovým zobrazováním. Hodnota denzity je měřena Hounsfieldovými jednotkami (HU) a vyjadřuje míru absorpce záření v jednotlivých tkáních, vztaženou k absorpci rengenového záření ve vodě ([35]).

$$\text{denzita (HU)} = \frac{\mu_{\text{mat}} - \mu_{\text{vody}}}{\mu_{\text{vody}}} \times 1000 \quad (3.1)$$

Rozsah hodnot výsledného obrazu je  $-1000HU$  až  $+3000HU$ . Hodnoty některých tkání jsou uvedeny v tabulce 3.1. Pro zobrazení CT se používá šedotónový obraz. Pro zobrazení velkého rozsahu jasů se používají tzv. “okénka” (window). Podle typu tkání, které mají být zobrazeny, se volí “úroveň okénka” (window level), jiným názvem “střed okénka” (window center). Dalším parametrem je šíře okna (window width). Hodnoty nad horní hranicí jsou zobrazeny bíle, hodnoty pod dolní hranicí jsou zobrazeny jako černé. Tabulka 3.2 uvádí užívaná nastavení okének pro vybrané tkáně.

U parenchymatozních orgánů je zpravidla střed okénka nastaven na denzitu vyšetřovaného orgánu a šíře je volena 90 až 500 HU. Hodnocení kostí je prováděno oknem



**Obrázek 3.3:** Vlevo: snímek mozku z výpočetní tomografie z roku 1971 [3]. Vpravo: CT snímek publikovaný v roce 2008 [37]

Druh tkáně	Denzita
Kosti, kalcifikace	> 85 HU
Sražená krev (koagulum)	65 až 85 HU
Měkké tkáně	25 až 70 HU
Tekutinné útvary (likvor, moč, obsah cyst, ...)	0 až 15 HU
Tuk	-40 až -120
Vzdušná plíce	-800 až -900 HU

**Tabulka 3.1:** Density některých typů tkání v Hounsfieldových jednotkách, převzato z [86]

Objekt	šíře okénka	střed okénka
Břicho	200 až 500	40
Hrudník - madastinum	300 až 500	40
Plicní parenchym	1500 až 2000	-500 až -700
Páteř	350 až 1000	40 až 60
Očnice	400 až 1000	40 až 60
Mozek	70 až 120	35
Kosti	500 až 4000	100 až 300

**Tabulka 3.2:** Okénka pro pozorování různých tkání, převzato a upraveno z [35]

se středem 100 až 300 HU a se šíří okna 500 a více HU. Plicní parenchym je zpravidla hodnocen pomocí okna se středem -500 až -700 HU.

Způsob zobrazení dat hraje v lékařství velkou roli. Například rentgenový snímek s pouhým invertováním jasů, kde se kosti zobrazují černě a zbytek bíle, je pro lékaře jen těžce čitelný. Velkou roli hraje zažitá zkušenost a změny jsou přijímány velmi zdrženlivě.

Nevýhodou této zobrazovací metody je zátěž pacienta ozářením. Zátěž se měří v Sieverttech (Sv). Ten je jednotkou ekvivalentní (efektivní) dávky ionizujícího záření. Poměříje biologické účinky jakéhokoliv záření s definovanou dávkou (1 Gray) Röntgenového záření. Zjednodušeně lze říci, že jeden Sievert má vždy stejné biologické účinky. Účinky lze rozdělit na deterministické a stochastické. Deterministické se projevují až při překročení určité prahové hodnoty (např. nemoc z ozáření). Nejzávažnějším stochastickým účinkem je vznik zhoubných nádorů. Běžný rentgen hrudníku zatíží pacienta 0,02 mSv (Sieverty). CT hrudníku však způsobí zátěž 5.8 Sv, což je 380 krát více (viz [134]). Ionizujícímu záření je člověk vystaven i v běžném prostředí. Efektivní dávka přírodního pozadí lokálně kolísá v rozmezí 1,5 – 7,5 mSv/rok ([86]).


Z hlediska modelování jater je podstatné, že míra absorpce rentgenového záření toho parenchymu je velmi podobná dalším tkáním, které na něj bezprostředně přiléhají. Jedná se zejména o srdce a žaludek. Obrázek 3.4 ukazuje rozložení jasů (měřeno Hounsfieldovými jednotkami) jater a okolní tkáně.

Nejběžněji se lze setkat s CT přístroji, které jsou využívány pro diagnostiku v medicíně. V praxi je však výpočetní tomografie využívána i například v archeologii, ale i v materiálových vědách. Některé z požadavků těchto oborů nelze uspokojit pomocí lékařského CT, ale je nutné použít více specializovaný přístroj. Například právě v materiálovém výzkumu hraje významnou roli dostatečné prostorové rozlišení trojrozměrného obrazu. Stroje označované jako Mikro-CT jsou schopny vytvářet obrazy s násobně lepším rozlišením. To je zajištěno odlišnou konstrukcí přístroje. Rentgenka i snímač jsou zde pevně umístěny, zatímco snímáný vzorek se otáčí. Tato konstrukce je nazývána Cone Beam Computed Tomography (CBCT). To, co by způsobovalo nepřijatelná omezení v klinickém použití, v těchto aplikacích nevádí. Cenou za kvalitní zobrazení dat je tak delší doba snímání, omezení maximální velikosti vzorku a vyšší míra radiační zátěže vzorku.

Konkrétním příkladem přístroje je Micro-CT Xradia XCT 400, které je využíváno na pracovišti Nové Technologie Výzkumné Centrum při Západočeské Univerzitě v Plzni. Obrázek 3.5 ukazuje uspořádání zdroje, detektoru a rotující platformy pro umístění vzorku. Přístroj má rengenku (Hamamatsu) pracující s napětím 20 - 90 KV. S velikostí pixelů v rozmezí 0.3 až 20 mikrometrů. Maximální velikost vzorku je 70 cm. Velikost snímáné oblasti však určuje kvalitu rozlišení. Čím je vzorek menší, tím lepšího rozlišení lze dosáhnout.

## 3.2 Magnetická rezonance

Magnetická rezonance (MR, nebo MRI - Magnetic Resonance Imaging) je neinvazivní vyšetřovací metoda, která se od konce 70. let začala uplatňovat v medicíně. Je založena



**Obrázek 3.4:** Histogram jater a okolní tkáně. Tkáň jater je značena černou barvou, okolní tkáň je vyznačena šedou barvou




**Obrázek 3.5:** Mikro-CT Xradia XCT 400 (NTC ZČU Plzeň). Pravý obrázek znázorňuje uspořádání zdroje záření, detektoru a rotující platformy pro upnutí vzorku



## 3.2 Magnetická rezonance

na rozdílných magnetických vlastnostech atomových jader různých prvků. Princip je odvozen od nukleární magnetické rezonance (NMR), která je využívána v analytické chemii. Prudký rozvoj výpočetní techniky vytvořil předpoklady pro využití metody pro zobrazování v medicíně.

Fyzikální princip magnetické rezonance využívá toho, že jádra s lichým nukleonovým číslem mají magnetický moment, který je vyvolaný rotací kolem své osy (spinem). Atom vodíku  $^1\text{H}$  je typickým představitelem této skupiny. Hojný výskyt v živých tkáních (lidské tělo je tvořeno z více jak 60% z vody) z něj činí ideální objekt využitelný pro zobrazování pomocí MR. Za normálních okolností dochází u těchto prvků k nahodilé orientaci magnetické rotační osy jednotlivých protonů. Díky tomu se vlivy jednotlivých jader vzájemně ruší. Pokud je však tkáň vystavena vlivu magnetického pole, uspořádají se protony svými rotačními osami rovnoběžně se siločarami vnějšího pole. Rotační osa



**Obrázek 3.6:** Znázornění spinu a precese. Spin vzniká rotací protonu kolem své osy. Proton umístěný do magnetického pole vykonává ještě další pohyb - precesi. Vektor spinu se pak pohybuje po plášti pomyslného kužele. Převzato z [86]

protonu vykonává precesní pohyb. Rotační i precesní pohyb je zobrazen na obrázku 3.6. Frekvence tohoto pohybu (tzv. Larmorova frekvence) je dána magnetickými vlastnostmi atomového jádra a silou vnějšího magnetického pole ([128]). Vztah je dán Larmorovou rovnicí:


$$\omega_0 = \gamma \cdot B_0 \quad (3.2)$$

$\omega_0$  je zde Larmorova frekvence,  $\gamma$  představuje gyromagnetický poměr, který je pro daný typ atomu konstantní. Pro vodíková jádra je jeho hodnota 42,577 MHz/T.  $B_0$  udává intenzitu magnetického pole v jednotkách magnetické indukce (Tesla).

Abychom uvedli protony z jejich ustálené polohy, je nutné dodat jim energii. To lze zařídit vysláním elektromagnetického impulzu o frekvenci stejné, jako je Larmorova frekvence (např. při intenzitě 1,5T je Larmorova frekvence 63,87 MHz). Na principu rezonance dojde k vychýlení magnetického momentu a synchronizaci precese všech protonů. Po skončení pulzu dochází postupně k návratu do ustáleného stavu. Čas, potřebný k tomuto návratu, se nazývá relaxační čas T1. Doba “rozsynchronizování” precese je označována jako relaxační čas T2. Oba časy jsou závislé na složení hmoty v okolí zkoumaných

### 3.3 Srovnání CT a MR z pohledu počítačového vidění

protonů ([86]). Signál, který získáváme po sérii pulzů (tzv. sekvenci), má charakter elektromagnetického vlnění. Měříme jej pomocí přijímacích cívek. Vhodnou volbou sekvence lze získat T1-vážený obraz, nebo T2-vážený obraz, viz 3.7.



**Obrázek 3.7:** Zobrazení T1-váženého obrazu (A) a T2-váženého obrazu (B). Část, která je na T1-váženém obraze hypointenzitní, je na T2-váženém obraze hyperintenzitní, převzato a upraveno z [10]


Detailní popis principu MR, kódování a rekonstrukce obrazu lze nalézt v [128]. Princip kódování polohy však lze naznačit na ukázce volby řezu. Použitím gradientního vnějšího magnetického pole (s rostoucí intenzitou v různých místech měření) je Larmorova frekvence v odlišných částech obrazu různá (viz obrázek 3.8). Volbou vhodné frekvence budícího pulzu lze uvést do rezonance jen protony ve vybraném řezu a měřit pouze jejich elektromagnetickou odezvu.

Z hlediska diagnostiky je nutno podotknout, že stejné struktury mají pro různé sekvence odlišné intenzity signálu. Tekutina je například na T1- vážené sekvenci hypersignální (vysoká intenzita), na T2- vážené sekvenci je hyposignální (nízká intenzita). Tuk má na většině sekvencí vysokou intenzitu. Kompaktní kosti oproti tomu obsahují minimální množství vody a jsou bez signálu. Odezvu některých tkání na základní typy sekvencí uvádí tabulka 3.3.

### 3.3 Srovnání CT a MR z pohledu počítačového vidění

Magnetická rezonance a výpočetní tomografie pracují na velmi odlišném fyzikálním principu. Výpočetní tomografie vyniká nad MR prostorovým rozlišením obrazu. Naměřené hodnoty mají pevně stanovené jednotky a díky tomu z nich lze při analýze vycházet

### 3.3 Srovnání CT a MR z pohledu počítačového vidění



**Obrázek 3.8:** Znázornění aplikace roviny řezu určujícího gradientu, převzato z [128]

	T1-vážená sekvence	T2-vážená sekvence
tekutina	hypointenzivní	hyperintenzivní
parenchymatozní orgány	střední intenzita	střední intenzita
tuk	hyperintenzivní	mírně hyperintenzivní

**Tabulka 3.3:** Intenzity signálu MR některých tkání v základních typech sekvencí. Převzato a upraveno z [86]

(viz tabulka 3.1. Na druhou stranu magnetická rezonance předčí Computed Tomography (CT) v rozlišení tkání pomocí rozdílů intenzity signálu. Díky rozsahu nastavení lze v intenzitě dosáhnout velkého rozlišení. Intenzita však nemá stanovené jednotky. Absolutní hodnoty obrazových bodů každého vyšetření jsou dány řadou parametrů. V potaz lze tedy brát jen relativní vztahy.

Přes řadu rozdílů lze najít mnoho společných vlastností. Data získaná z obou modalit jsou dána řezy. Vzájemná poloha řezů je jasně definovaná - řezy jsou rovnoběžné. To není samozřejmě například u sonografických vyšetření, kdy je vzájemná poloha řezů nedefinovaná. Další společnou vlastností je jednokanálový (šedotónový) výstup. Velkou výhodou CT je existence pevně stanovených jednotek intenzity signálu. Toho lze při texturní analýze s výhodou využívat. Na druhou stranu, významnou vlastností metod pro zpracování textur, je nezávislost na absolutních hodnotách jasu. Metody hodnotí strukturu nezávisle na konkrétním jasu. Díky tomu není využívání dat magnetické rezonance žádným problémem. Dalším společným znakem je relativně velká rozlišovací schopnost obou přístrojů. Hrana voxelu obou přístrojů je menší než jeden milimetr. Výpočetní tomografie má zpravidla rozlišení ještě lepší. Společným znakem je rovněž velmi dobré zachycení anatomických struktur v obraze. Tím se obě modalit odlišují například od zobrazování pomocí nukleární metody SPECT. Ta zachycuje zejména funkci různých tkání. V obraze (s významně menším rozlišením v porovnání s CT nebo MR) jsou pak jasné body v místech se zvýšenou funkcí. Z obrázku však není přímo patrná konkrétní lokalizace. Tu lze zjistit až registrací obrazu ze SPECT s obrazem z CT.

## 4

# Metody počítačového vidění pro zpracování trojrozměrných obrazů

Metody počítačového vidění zažívají v posledních letech období nevídaného rozmachu. Je to dáno levnější technologií získávání dat, ale i dostupným výpočetním výkonem pro zpracování těchto dat. V neposlední řadě se rovněž rozrůstají řady odborníků, kteří se v tomto oboru dobře orientují. Podobor medicínských zobrazovacích metod v tomto ohledu není výjimkou.

Tato kapitola si neklade za cíl seznámit čtenáře dokonale s celým oborem počítačového vidění. Pouze nabízí plochu pro seznámení se s metodami, které budou v dalším textu více využívány.


### 4.1 Příznaky pro popis oblastí

Zpracování obrazu je z mnoha důvodů složitou úlohou. Velkou část úkolů není možné řešit přímým výpočtem, ale je nezbytné využívat zjednodušení a heuristické postupy. V řadě algoritmů pro zpracování obrazu je použito zjednodušení o předpokladu rovnoměrnosti rozdělení intenzit v různých oblastech obrazu. Zjednodušeně řečeno se předpokládá, že povrch různých objektů je homogenní ve smyslu rozložení jasů. Tento předpoklad však není řadou reálných obrazů splněn. Například obrázek dřeva obsahuje celou řadu rozdílných jasů. Takovému vizuálnímu vzoru se říká textura.

Textury popisují vlastnosti povrchu či struktury objektu v obraze. Termín je hojně užíván a je intuitivně srozumitelný, ale přesná definice vzhledem k jejich variabilitě neexistuje [112].

Lidé mohou texturu popisovat jako jemnou, hrubou, pravidelnou, nepravidelnou, homogenní atd. Tyto charakteristiky jsou pro potřeby strojového zpracování poněkud vágní. Informace obsažené v textuře je možno nalézt v tónu nebo ve struktuře [48]. Tón je spojen s intenzitou jednotlivých pixelů, zatímco struktura vypovídá o jejich prostorovém uspořádání.

Texturní analýza se věnuje řešení čtyř hlavních problémů. Obecná klasifikace zařazuje objekty reálného světa do jedné z několika kategorií (tříd). Klasifikace textur



Obrázek 4.1: Různé druhy textur

zařazuje neznámé vzorky obrazu do tříd podle jejich texturních vlastností. Druhou oblastí texturní analýzy je segmentace ([102]). Jejím cílem je rozdělit obraz na části, které mají homogenní texturní vlastnosti. Dalším problémem je texturní syntéza. Zde je cílem vytvořit model, který bude možné použít pro generování textury. Poslední oblastí, které se věnuje texturní analýza, je vytvoření tvaru z textury. Dvourozměrný obraz (fotografie) je vzniklý projekcí trojrozměrného světa do dvojrozměrného prostoru. Cílem je zrekonstruovat trojrozměrný tvar objektu na základě analýzy textury jeho povrchu. Další text této práce bude věnován převážně prvním dvěma oblastem texturní analýzy, tedy klasifikaci a segmentaci.

Podle [123] lze metody pro analýzu textur rozdělit do čtyř skupin: statistické, geometrické, metody založené na modelu a metody vycházející ze zpracování signálů. Vzhledem k širokému spektru různých přístupů lze řadu metod řadit do více skupin. Jedna metoda tak může být různými autory zařazena do odlišných skupin.

#### 4.1.1 Statistický popis textury

Cílem statistického přístupu k popisu textury je vytvořit z jednotlivých příznaků, které popisují texturu, příznakový vektor. Ten umožní navrhnout rozhodovací pravidlo, pomocí kterého lze zařadit texturu do příslušné třídy.

##### Metody založené na statistikách prvního řádu

Statistiky prvního řádu měří podobnost na základě analýzy jasu v náhodně zvolené oblasti obrazu. Mohou být vypočítány z histogramu intenzit obrazu. Závisí pouze na

individuálních vlastnostech jasu každého pixelu a neodrážejí v nich žádné charakteristiky okolí pixelu.

Uvažujme že obraz  $I$  je náhodná proměnná reprezentující jasy obrazu v oblasti zájmu.  $P(I)$  je histogram, který udává (absolutní) četnosti jasů v dané oblasti.

$$P(I) = \frac{\text{počet pixelů s jasem } I}{\text{celkový počet pixelů v oblasti}} \quad (4.1)$$

Na základě histogramu (rov. 4.1) lze definovat další kvantifikátory, popsané v článku [49] a v knize [116], například obecné a centrální momenty (viz rovnice 4.2 a 4.3).

*Obecné momenty*

$$m_i = E [I^i] = \sum_{I=0}^{N_g-1} I^i P(I), \quad i = 1, 2, \dots \quad (4.2)$$

Kde  $N_g$  je počet odstínů šedi,  $I$  je jas a  $i$  je index momentu,  $m_0 = 1$ ,  $m_1 = E [I]$

*Centrované momenty*

$$\mu_i = E \left[ (I - E [I])^i \right] = \sum_{I=0}^{N_g-1} (I - m_1)^i P(I) \quad (4.3)$$

Je patrné, že  $m_0 = 1$  a  $m_1$  je rovno střední hodnotě  $I$ . Nejpoužívanějšími centrovanými momenty jsou  $\mu_2$ ,  $\mu_3$  a  $\mu_4$ .  $\mu_2 = \sigma^2$  a jedná se tedy o rozptyl,  $\mu_3$  a  $\mu_4$  jsou známy jako “šikmost” (anglicky skewness) a “špičatost” (kurtosis). Šikmost měří asymetrii histogramu kolem střední hodnoty, zatímco špičatost poukazuje na míru nahuštění jasů kolem středu histogramu. Někdy může být šikmost a špičatost normována pomocí  $\sigma^3$ , respektive  $\sigma^4$ . Obrázek 4.2 ukazuje šest variant stejného obrázku s šestnácti úrovněmi šedi.

*Absolutní momenty*

$$\hat{\mu}_i = E \left[ |I - E [I]|^i \right] = \sum_{I=0}^{N_g-1} |I - m_1|^i P(I) \quad (4.4)$$

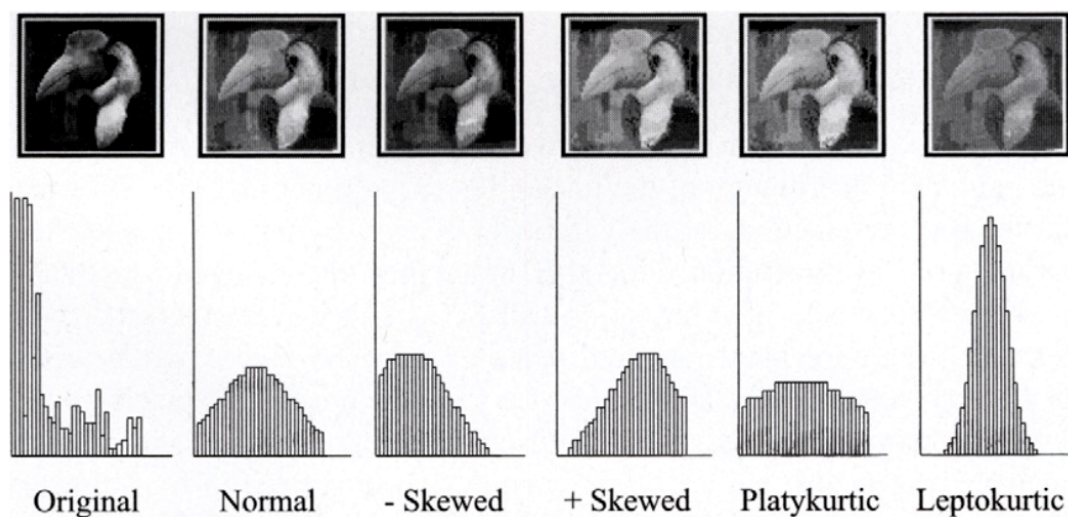
*Entropie*

$$H = -E [\log_2 P(I)] = - \sum_{I=0}^{N_g-1} P(I) \log_2 P(I) \quad (4.5)$$

Entropie měří rovnoměrnost histogramu, čím blíže je histogram rovnoměrnému rozdělení, tím vyšší je hodnota entropie.

### Statistiky druhého řádu

Metody zmiňované v předchozí části pracují s obrazem jako s náhodnou veličinou. Vyhodnocují míru zastoupení podobných jasů, nezohledňují však prostorové uspořádání jednotlivých obrazových bodů v obraze. Není nijak obtížné vytvořit dvě různé textury,




**Obrázek 4.2:** Ukázka obrázků a příslušných histogramů: (Original) původní obraz, (Normal) normální rozložení jasů, (-Skewed) záporná šikmost, (+Skewed) kladná šikmost, (Platykurtic) nízká špičatost, (Leptokurtic) vysoká špičatost, převzato z [116]

	Orig	Norm	-Skew	+Skew	Plat	Lept
$\mu_3$	587	0	-169	169	0	0
$\mu_4$	16609	7365	7450	7450	9774	1007
H	4.61	4.89	4.81	4.81	4.96	4.12


**Tabulka 4.1:** Hodnoty entropie a třetího a čtvrtého momenty pro data z obrázku 4.2, převzato z [116]

kteří budou mít shodné histogramy. Shoda histogramů však rovněž znamená i shodu všech charakteristik z předchozí části (statistik prvního řádu), a tedy i nerozlišitelnost takovýchto textur na základě zmíněných přístupů přístupů. Příklad takové situace je možný nalézt na obrázku 4.3.



Obrázek 4.3: Textury se stejným histogramem

Statistiky druhého řádu jsou dány pozorováním párů jasových hodnot v definované vzájemné poloze na náhodném místě obrazu. Informaci o vzájemné poloze jednotlivých pixelů umožňuje vyhodnocovat matice sousednosti, která je sestavena na základě statistik druhého řádu. Využívá opakování rozložení jasů v textuře. Při jejím sestavování jsou brány v potaz dva další parametry. Jedním je maximální vzájemná vzdálenost dvou pixelů, daná poloměrem okolí  $d$ , a druhým je vzájemná orientace  $\phi$ , která je kvantizována do čtyřech směrů – horizontální, vertikální a dva šikmé směry ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  a  $135^\circ$ ), jak ukazuje obrázek 4.4 Matice sousednosti je pak určena pro kombinace  $d$  a  $\phi$ . Každý



Obrázek 4.4: Směry používané k vytvoření matice sousednosti

prvek  $P(I_1, I_2)$  této matice pak ukazuje poměrné množství pixelů s jasnem  $I_1$ , které jsou do vzdálenosti  $d$  ve směru  $\phi$  od pixelu s jasnem  $I_2$ .



$$\begin{aligned}
 0^\circ : P(I(m, n) = I_1, I(m \pm d, n) = I_2) &= \\
 &= \frac{\text{počet párů pixelů do vzdálenosti } d \text{ s hodnotami } I_1 \text{ a } I_2}{\text{celkový počet možných párů}} \quad (4.6) \\
 45^\circ : P(I(m, n) = I_1, I(m \pm d, n \mp d) = I_2) & \\
 90^\circ : P(I(m, n) = I_1, I(m, n \pm d) = I_2) & \\
 135^\circ : P(I(m, n) = I_1, I(m \pm d, n \pm d) = I_2) &
 \end{aligned}$$

Jako příklad vytvoříme matici sousednosti pro obrázek  $I$  (matice 4.7).

$$I = \begin{bmatrix} 0 & 1 & 2 & 2 \\ 1 & 1 & 2 & 3 \\ 0 & 0 & 0 & 3 \\ 0 & 1 & 3 & 3 \end{bmatrix} \quad (4.7)$$

Matice sousednosti pro  $d = 1$  a  $\phi = 0^\circ$  pak ukazuje počet dvojic jasů, které spolu sousedí v horizontálním směru, vydělený maximálním počtem takových dvojic.

$$A^0(d = 1) = \frac{1}{24} \begin{bmatrix} 4 & 2 & 0 & 1 \\ 2 & 2 & 2 & 1 \\ 0 & 2 & 2 & 1 \\ 1 & 1 & 1 & 2 \end{bmatrix} \quad (4.8)$$

Ve zjednodušené formě lze matici sousednosti sestavit nezávisle na směru  $\phi$ . Prvky  $P(i, j)$  takové matice pak udávají počet jasů  $i$  sousedících s jasem  $j$ .

*Angular Second Moment*

$$\text{ASM} = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (P(i, j))^2 \quad (4.9)$$

Angular Second Moment (někdy známé jako energie) vyjadřuje míru hladkosti. Nabývá vysokých hodnot pro hladké obrazy. Pokud mají všechny pixely obrazu stejný jas  $I = k$ , pak  $P(k, k) = 1$  a na ostatních místech matice sousednosti jsou nuly. Druhá mocnina pak zvýrazní malý počet vysokých čísel.

*Kontrast*

$$\text{CON} = \sum_{i=0}^{N_g-1} n^\lambda \left\{ \sum_{i=0}^{N_g-1} \sum_{|i-j|=n}^{N_g-1} P(i, j) \right\} \quad (4.10)$$

Kontrast měří lokální změny v obraze. Pro obrazy s vysokým kontrastem nabývá  $CON$  velkých hodnot. Člen  $n^\lambda$  váží více velké rozdíly.  $\lambda$  se zpravidla volí  $\lambda = 2$ .

*Inverzní diferencní moment*

$$\text{IDF} = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{P(i, j)}{1 + (i - j)^2} \quad (4.11)$$

	Levý	Pravý
$\mu_2$	12.227	12.227
$\mu_3$	-3.6791	-3.6335
$\mu_4$	150.615	150.6019
Contrast	3.4035	24.4346
Korelace	0.8608	0.0008
Energie	0.4363	0.2509
Homog	0.9392	0.5637

**Tabulka 4.2:** Hodnoty některých příznaků pro textury z obrázku 4.3

Díky dělení členem  $(i-j)^2$  nabývá *IDF* velkých hodnot pro obrazy s malým kontrastem.  
*Entropie*

$$H_{xy} = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j) \log_2 P(i, j) \quad (4.12)$$

Entropie měří náhodnost obrazu, nabývá nízkých hodnot pro hladký obraz.

Metody založené na statistikách druhého řádu poskytují dobré výsledky v řadě úloh díky zachycení a hodnocení informace o vzájemné poloze různých jasů a jejich prostorovém rozložení. Nevýhodou těchto přístupů jsou velké paměťové nároky. Velikost matic sousednosti lze redukovat snížením počtu jasových úrovní (například na 32), tím však nevyhnutelně dochází ke ztrátě informace a zhoršení výsledků.

Tabulka 4.2 umožňuje porovnat některé texturní příznaky vycházející ze statistik prvního řádu s příznaky, které využívají analýzu matice sousednosti. Hodnoty jsou vypočteny pro textury z obrázku 4.3. Ukazuje se, že velmi rozdílné textury mohou mít shodné charakteristiky prvního řádu. V takovém případě je analýza matice sousednosti jedním z možných řešení.

### Příznaky používající počet opakování jasů

Velké plochy s podobným jasem jsou typické pro hrubé textury, jemné textury mají plochy malé. V článku [42] je popsána řada příznaků, které vycházejí z této vlastnosti. Počet opakování jasů (anglicky *Gray Level Run Length*) udává počet souvislých pixelů v řadě, které mají stejný jas. Počty výskytů běhu určité délky o daném jasu pak mohou dostatečně charakterizovat texturu.

Tyto výskyty jsou pak uspořádány do matice  $Q_{RL}$ , která rozměr  $N_g \times N_r$ , kde  $N_r$  je nejdelší možný běh v obraz a lze ji počítat pro každý směr ( $0^\circ$ ,  $45^\circ$ , ...) Například matice (4.13) jsou vytvořeny z obrázku *I* 4.7 pro směry  $0^\circ$  a  $90^\circ$ .

$$Q_{RL}(0^\circ) = \begin{bmatrix} 2 & 0 & 1 & 0 \\ 2 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 2 & 1 & 0 & 0 \end{bmatrix} \quad Q_{RL}(90^\circ) = \begin{bmatrix} 3 & 1 & 0 & 0 \\ 2 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \end{bmatrix} \quad (4.13)$$

V řádcích matice jsou uvedeny počty běhů určitého jasu pro různé délky. Například první prvek  $Q_{RL}(0,0)$  udává kolikrát stojí jas „0“ v zadaném směru samostatně. Druhý prvek na prvním řádku udává, kolikrát se stejný jas objevil v obraze ve dvojici (v patřičném směru). Třetí prvek pak informuje počtu trojic jasu „0“.

Na základě matice  $Q_{RL}$  lze stanovit několik možných příznaků

*Zvýraznění krátkých opakování – Short Run Emphasis*

$$SRE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (Q_{RL}(i,j)/j^2)}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} Q_{RL}(i,j)} \quad (4.14)$$

Určitá forma celkového počtu opakování jasů v obraze. Kvůli dělení  $j^2$  však zvýrazňuje krátké běhy.

*Zvýraznění dlouhých opakování - Long Run Emphasis*

$$LRE = \frac{\sum_{i=1}^{N_r} \sum_{j=1}^{N_g} (Q_{RL}(i,j) \cdot j^2)}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} Q_{RL}(i,j)} \quad (4.15)$$

Zvýrazňuje dlouhé běhy kvůli násobení  $j^2$

*Nerovnoměrnost jasových úrovní - Gray Level Nonuniformity*

$$GLNU = \frac{\sum_{i=1}^{N_g} \left[ \sum_{j=1}^{N_r} Q_{RL}(i,j) \right]^2}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} Q_{RL}(i,j)} \quad (4.16)$$

Část výrazu v závorkách představuje celkový počet běhů pro každou úroveň jasu. Čím větší je rovnoměrnost jasů v obraze, tím menší je hodnota  $GLNU$ .

*Nerovnoměrnost délky opakování*

$$RLN = \frac{\sum_{i=1}^{N_r} \left[ \sum_{j=1}^{N_g} Q_{RL}(i,j) \right]^2}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} Q_{RL}(i,j)} \quad (4.17)$$

$RLN$  (Run Length Nonuniformity) měří nerovnoměrnost počtů opakování jasů. Čím nerovnoměrnější počty jsou, tím vyšších hodnot  $RLN$  nabývá.

*Míra zastoupení počtu opakování - Run Percentage*

$$RP = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} R_{RL}(i,j)}{L} \quad (4.18)$$

kde  $L$  je celkový počet opakování v obraze. Pokud mají všechny délky opakování délku jedna, je  $L$  rovno počtu pixelů v obraze.  $RP$  nabývá nízkých hodnot pro obrazy s plynulými přechody.

Článek [21] popisuje srovnání řady rozličných metod pro texturní analýzu. Příznaky vytvořené na základě opakování jasů v tomto srovnání poněkud zanikají a výkonově se nevyrovňají ostatním metodám.

### Geometrické momenty

Geometrické momenty jsou často užívány pro rozpoznávání, neboť poskytují bohaté informace o obraze. To je dáno tím, že momenty představují alternativní reprezentaci obrazu. Obraz může být zrekonstruován ze všech jeho momentů.

Máme-li spojitý obraz  $I(x, y)$ , geometrický moment  $m_{pq}$  je definován jako:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q I(x, y) dx dy \quad (4.19)$$

V úlohách zpracování obrazu je častým problémem nejistá orientace a poloha zobrazovaných objektů. Souvisí to se širokými možnostmi snímání obrazu scény. Častým požadavkem kladeným na různé deskriptory je stálost vůči posunu, otočení a změně měřítka obrazu.

Translace

$$x' = x + a, \quad y' = y + b \quad (4.20)$$

Rotace

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{bmatrix} \quad (4.21)$$

Změna měřítka

$$x' = \alpha x, \quad y' = \alpha y \quad (4.22)$$

Využitím vztahu 4.19 lze vytvořit centrované a normované momenty.

*Centrované momenty*

$$\mu_{pq} = \int \int I(x, y) (x - \bar{x})^p (y - \bar{y})^q dx dy \quad (4.23)$$

kde

$$\bar{x} = \frac{\mu_{10}}{\mu_{00}}, \quad \bar{y} = \frac{\mu_{01}}{\mu_{00}}$$

Centrované momenty jsou invariantní vůči translaci

*Normované centrované momenty*

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^{\frac{p+q+2}{2}}}, \quad \gamma = \frac{p+q+2}{2} \quad (4.24)$$

Normované centrované momenty jsou invariantní vůči translaci a změně měřítka.

Pro potřeby zpracování digitalizovaného obrazu lze stanovit diskrétní podobu výpočtu momentů nahrazením integrálů sumami.

$$m_{pq} = \sum_i \sum_j I(i, j) i^p j^q \quad (4.25)$$

kde  $I(i, j)$  je obraz s  $i = 0, 1, \dots, N_x - 1$  a  $j = 0, 1, \dots, N_y - 1$ .

Řada úloh vyžaduje zpracování obrazů s rozdílnou velikostí. V takových případech je vhodné normalizovat osy  $x$  a  $y$ . Toho je dosaženo zavedením nových souřadnic  $i$ -tého pixelu  $x_i$  a  $y_i$ . Ty nejsou celočíselné, ale reálné čísla na intervalu  $\langle -1, 1 \rangle$ .

$$m_{pq} = \sum_i I(x_i, y_i) x_i^p y_i^q \quad (4.26)$$

*Huovy momenty*

V článku [53] byla představena skupina sedmi tzv. Huových momentů. Jejich přehled uvádí 4.27. Všechny jsou invariantní vůči translaci, rotaci a změně měřítka. Prvních šest momentů je navíc invariantní vůči zrcadlení. Sedmý moment při zrcadlení pouze mění znaménko. V praxi je často užíván logaritmus absolutních hodnot Huových momentů.

$$\begin{aligned}
 p + q &= 2 \\
 \phi_1 &= \eta_{20} + \eta_{02} \\
 \phi_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \\
 p + q &= 3 \\
 \phi_3 &= (\eta_{30} - 3\eta_{12})^2 + (\eta_{03} - 3\eta_{21})^2 \\
 \phi_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{03} + \eta_{21})^2 \\
 \phi_5 &= (\eta_{30} - \eta_{12})(\eta_{30} - \eta_{12}) \left[ (\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2 \right] \\
 &\quad + (\eta_{03} - 3\eta_{21})(\eta_{03} + \eta_{21}) \left[ (\eta_{03} + \eta_{21})^2 - 3(\eta_{12} + \eta_{30})^2 \right] \\
 \phi_6 &= (\eta_{20} - \eta_{02}) \left[ (\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] \\
 &\quad + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{03} + \eta_{21}) \\
 \phi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) \left[ (\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2 \right] \\
 &\quad + (\eta_{03} - 3\eta_{21})(\eta_{03} + \eta_{21}) \left[ (\eta_{03} + \eta_{21})^2 - 3(\eta_{12} + \eta_{30})^2 \right]
 \end{aligned} \quad (4.27)$$

*Zernikeho momenty*

Představují další možnost tvorby příznakového vektoru. Jejich bázové funkce jsou na rozdíl od geometrických momentů (4.19), ortogonální. To představuje výhodu z pohledu redundance informace. Báze těchto momentů jsou odvozeny od Zernikeho polynomů. Jsou definovány jako:

$$V_{pq}(x, y) = V_{pq}(\rho, \theta) = R_{pq}(\rho) \exp(jq\theta) \quad (4.28)$$

kde platí že:

- $p$  je nezáporné celé číslo

- $q$  je celočíselné a vyhovuje vztahu  $|q| \leq p$
- $\rho = \sqrt{x^2 + y^2}$
- $\theta = \tan^{-1} \frac{y}{x}$
- a  $R_{pq}(\rho)$  je definován jako:

$$R_{pq}(\rho) = \sum_{s=0}^{(p-|q|)/2} \frac{(-1)^s [(p-s)!] \rho^{p-2s}}{s! \left(\frac{p+|q|}{2} - s\right)! \left(\frac{p-|q|}{2} - s\right)!}$$

Zernikeho momenty jsou pak definovány následujícím vzorcem:

$$A_{pq} = \frac{p+1}{\pi} \iint_{x^2+y^2 \leq 1} I(x, y) V^*(\rho, \theta) dx dy \quad (4.29)$$

Pro diskrétní digitální obrazy je výpočet dán vztahem

$$A_{pq} = \frac{p+1}{\pi} \sum_i I(x_i, y_i) V^*(\rho_i, \theta_i), \quad x_i^2 + y_i^2 \leq 1 \quad (4.30)$$

Index  $i$  označuje jednotlivé pixely. Výpočet však není prováděn nad všemi obrazovými body. Souřadnice  $x_i$  a  $y_i$  jsou dány vztahem  $x_i^2 + y_i^2 \leq 1$ , který omezuje působnost momentů na jednotkovou kružnici v kolem středu obrazu. Pixely za touto hranicí nemají na výsledek žádný vliv. Zernikeho momenty nejsou přímo invariantní vůči rotaci, translaci a změně měřítka, ale tyto problémy je možné řešit. Například lze ukázat souvislost mezi hodnotou momentu před natočením a po natočení.

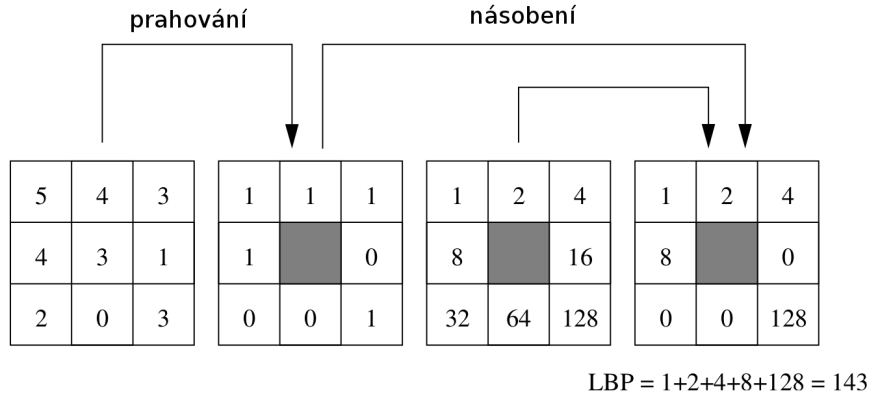
$$A'_{pq} = A_{pq} \exp(-jq\theta) \quad (4.31)$$

Existuje celá řada dalších podobných momentů. Například momenty založené na Legendreových polynomech, nebo Fourier-Mellinovy momenty. Ty vycházejí z převedení frekvenčního prostoru po Fourierově transformaci z kartézského do polárního souřadného systému. Tím je zajištěna invariance vůči translaci, rotaci a změně měřítka. Více se lze dočíst v [108].

### Local Binary Patterns

Příznaky pro klasifikaci textur nazývané Local Binary Patterns (LBP) se poprvé objevily článku [87]. Autoři se zde věnují hledání popisu textury v okolí pixelu jediným číslem. Klasifikace pak probíhá na základě histogramu těchto popisujících čísel v celém obrazu (nebo jeho části). Jsou zde popsány různé metody tvorby příznaku a jednou z nich je právě LBP.

Základní varianta LBP kódu je vytvářena na základě osmi-okolí každého pixelu. Toto okolí je prahováno hodnotou středového pixelu. Tím je získána osmice jedniček a nul,



Obrázek 4.5: Výpočet LBP kódu, převzato z [79]

kteřá představuje zápis LBP kódu ve dvojkové soustavě. Celý proces je naznačen na obrázku 4.5. Velikost hodnoty LBP kódu nemá smysluplnou geometrickou nebo grafickou interpretaci, lze s ní však pracovat statisticky. Například neparametrickým statistickým testem, který porovnává dvojici histogramů.

Vzhledem k tomu, že LBP jsou z principu nezávislé na monotonních změnách v obrazy, byl odvozen princip pro měření lokálního kontrastu. Tento kontrast je počítán průměrováním jasů okolních pixelů, které jsou větší nebo rovny středovému pixelu, a odečtením průměru hodnot pixelů menších. Toto měření je nazýváno LBP/C. Příklad kontrastu vypočteného na základě obrázku 4.5 je v následující rovnici

$$C = (5 + 4 + 3 + 3 + 4)/5 - (1 + 0 + 2)/3 = 2,8 \quad (4.32)$$

V článku [87] bylo LBP/C měření použito pro popis textur a bylo dosaženo velmi dobrých výsledků při klasifikaci textur z Brodatzových fotografií ([17]).

*Klasifikace neparametrickým testem*

Při klasifikaci je měřena rozdílnost mezi vzorkem a modelem LBP hustoty pomocí neparametrického statistického testu. Klasifikace pak probíhá zařazením do třídy s nejmenší rozdílností. Například lze použít následující kritérium:

$$G(S, M) = 2 \sum_{b=1}^B \log \frac{S_b}{M_b} \quad (4.33)$$

kde  $S$  je vzorek a  $M$  je model distribuční funkce (histogramu).  $S_b$  a  $M_b$  odpovídají jednotlivým sloupcům distribuční funkce.  $B$  je celkový počet sloupců.

Při malém počtu vzorků může být použito kritérium Chí-kvadrát:

$$\chi^2 = \sum_{b=1}^B S_b \frac{(S_b - M_b)^2}{S_b + M_b} \quad (4.34)$$

Téměř stejné přesnosti může být dosaženo použitím následujícího kritéria. Výhodou je podstatné snížení výpočetních nároků.

$$H(S, M) = \sum_{b=1}^B \min(S_b, M_b) \quad (4.35)$$


*Rozšíření základní myšlenky Local Binary Patterns*

Základní přístup popisu textury pomocí LBP je odolný vůči změnám v jasů obrazu. Je použitelný v řadě aplikací, kdy je možné předkládat ke klasifikaci textury získané neměnným způsobem, avšak pro velkou skupinu úloh je nepoužitelný z důvodu neschopnosti vypořádat se s natočením a zvětšením.

V článku [89] je představeno několik rozšíření původní myšlenky právě s ohledem na invarianci popisu vzhledem k natočení a zvětšení. Následující rovnice popisují LBP poněkud formálněji a obecněji. Vychází se z definice textury  $T$  jako skupině  $P + 1$  jasových úrovní pixelu obrazu, kde  $P > 0$ .

$$T = t(g_c, g_0, \dots, g_{P-1}) \quad (4.36)$$

$g_c$  je zde středový pixel a  $g_p$  jsou hodnoty jasů okolních pixelů rozložených na kružnici o poloměru  $R$ , kde  $R > 0$ . Kruhové okolí pro různé parametry  $P$  a  $R$  ukazuje obrázek 4.6.



**Obrázek 4.6:** Kruhové okolí LBP s různými parametry, převzato z [89]

Od  $g_p$  může být beze ztráty informace odečteno  $g_c$ .

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

Za předpokladu, že  $t(g_c)$  popisuje celkové osvětlení, které nemá vztah k textuře, může být vynecháno

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



K zajištění invariance vůči změně měřítka jasových úrovní (například přeškálování jasů z rozsahu  $0 - -255$  na rozsah  $0 - -1$ ) jsou brány v potaz jen znaménka  $g_p - g_c$ .

$$T \approx t(s(g_0 - g_c), \dots, s(g_{P-1} - g_c)) \quad (4.37)$$

Kde

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4.38)$$

Přepis do LBP kódu je realizován přiřazením vah  $2^p$  ke každému znaménku  $s(g_p - g_c)$ :

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (4.39)$$

#### *Invariance vůči natočení*

K vyřešení závislosti na natočení je potřeba otáčet LBP vzorek do základní pozice. Otáčení znamená přepisování nul a jedniček ze dvojkové reprezentace kódu ze začátku kódu na jeho konec. Základní pozici lze zvolit různými způsoby. Jednoduchou základní pozicí je taková pozice, ve které má LBP kód po vyčíslení nejmenší hodnotu. Vzorec pro LBP invariantní vůči natočení udává rovnice 4.40

$$LBP_{P,R}^i = \min \{ROR(LBP_{P,R}, i)\} \quad i = 0, 1, \dots, P - 1 \quad (4.40)$$

#### *Uniformní Local Binary Patterns*

Pro účely klasifikace je užíván histogram, který je poměrně dlouhý. Pro  $P = 8$  obsahuje 255 sloupců. V článku [80] byl představen způsob, jak vektor zmenšit. Myšlenka je založena na používání uniformních LBP kódů. Uniformnost  $U$  je měřena počtem přechodů mezi nulou a jedničkou. Ukázkou měření uniformity ukazuje rovnice 4.41

$$\begin{aligned} U(00001100) &= 2 \\ U(00000000) &= 0 \\ U(11000011) &= 2 \\ U(01011100) &= 4 \\ U(10010010) &= 6 \\ U(10101010) &= 8 \end{aligned} \quad (4.41)$$

V článku je zmíněna teorie, že čím menší je uniformita kódu, tím větší je jeho informační hodnota. Na základě toho je doporučeno používat takové LBP, které obsahují nejvýše dva přechody mezi nulou a jedničkou. Tedy kódy 00000000, 00000001, 00000011, 00000111, 00001111, 00011111, 00111111, 01111111, 11111111 a jejich rotace. Celkem se jedná o 58 kódů z 256. Zbylé kódy jsou přiřazeny do jedné skupiny (59). Celkem je tedy velikost vektoru 59. V praxi se toto zpravidla realizuje vyhledávací tabulkou. Zmenšení příznakového vektoru se příznivě projevuje snížením výpočetních nároků.

#### *Víceměřítkové LBP*

Využitím této techniky lze řešit problémy s různým zvětšením textur. Základ myšlenky je v kombinaci  $N$  různých LBP operátorů s rozličnými parametry  $P$  a  $R$ . Díky tomu nabude každý pixel  $N$  různých LBP kódů.

Celkovou rozdílnost je pak možné počítat jako součet rozdílností dílčích rozložení.

$$L_N = - \sum_{n=1}^N L(S^n m M^n) \quad (4.42)$$

Kde  $S^n$  je naměřená hustotní funkce neznámého vzorku a  $M^n$  je hustotní funkce modelu s  $n$ -tým LBP operátorem.

### 4.1.2 Geometrické metody

Geometrické metody jsou skupinou metod pro analýzu textur, chápou textury jako složeniny z různých texturních elementů či primitiv. Výsledky jsou zpravidla závislé na geometrických vlastnostech textur. Nejprve jsou v obrazu nalezeny texturní elementy. Ty jsou pak popsány statistickým způsobem. Alternativním přístupem je snaha zachytit pravidla v rozmístění jednotlivých elementů.

#### Deskriptory založené na analýze hran

Metody určené pro analýzu hran mohou, kromě svého primárního určení, sloužit i k popisu textur. Hrana je v takovém případě považována za strukturní element. Jejich výskyt pak lze analyzovat a na základě analýzy vytvořit popis textury. Článek [26] je věnován rozšíření matice sousednosti na hranový obraz.

Pro detekci hran je možné použít Robertsův gradientní operátor, ale v zásadě lze použít i jakýkoliv jiný. Stejně tak lze použít následující funkci:

$$g(d) = |f(i, j) - f(i+d, j)| + |f(i, j) - f(i-d, j)| + |f(i, j) - f(i, j+d)| + |f(i, j) - f(i, j-d)| \quad (4.43)$$

Z analýzy statistik prvního a druhého řádu obrazu hran lze pak sestavit řadu příznaků pro popis.

**Hrúbost** odpovídá hustotě hran. S rostoucí hrúbostí textury klesá počet hran v obraze.

**Kontrast** lze odvozovat od prudkých hran v obraze, a tím vysokých odezev hranových operátorů.


**Náhodnost** měříme jako entropii histogramu hranového obrazu.

**Směrovost** aproximativní měření směrovosti může být realizováno jako entropie histogramu směrů hran.

**Linearita** je zjišťována v matici sousednosti páry, kde se hledají páry se stejným směrem hrany (viz obrázek 4.7, hrany  $a$  a  $b$ ).

**Periodicita** se měří pomocí matice sousednosti hran se stejným směrem hrany, kde párový bod leží kolmo ke směru hrany. Na obrázku 4.7 to demonstrují hranové body  $a$  a  $c$ .

**Velikost** je indikována v matici sousednosti jako páry hran s opačným směrem, které leží kolmo ke směru hrany. Tento případ ukazuje obrázek 4.7, hrany  $a$  a  $c$ .



**Obrázek 4.7:** Měření texturní lineariry, periodicity a velikosti pomocí hran obrazu, převzato z [118]

### Voronoi mozaikování

Jednou z možností, jak popisovat texturu s respektováním geometrických vlastností, představuje Voronoi mozaikování. Tato technika se zabývá rozdělením prostoru v okolí bodů. Podrobnosti lze nastudovat v [6] nebo v [9].


Voronoi diagram  $V(P)$  představuje rozklad množiny bodů  $P$  na  $n$  uzavřených či otevřených oblastí  $V(p) = \{V(p_1), V(p_2), \dots, V(p_n)\}$  takových, že každý bod  $q \in V(p_i)$  je blíže k bodu  $p_i$  než k jakémukoliv bodu  $p_j \in P$ . Pro libovolný bod  $q \in V(p_i)$  a libovolnou buňku  $V(p_j)$  platí

$$d(q, p_i) \leq d(q, p_j) \quad (4.44)$$

Uzavřená oblast  $V(p_i)$  je nazývána Voronoiovou buňkou.

Jak takový rozklad prostoru vypadá ilustruje obrázek 4.8. V článku [122] byla představena metoda využívající tento rozklad pro potřeby texturní segmentace. Vychází se z obrazu, na kterém jsou pouze jednotlivé body. Obraz je pomocí Voronoi rozkladu rozdělen do buněk, nad jejichž tvarem je realizována analýza. Ta je prováděna pomocí momentů, které jsou podobné geometrickým momentům v části 4.1.1. Rozdílem je neuvážování intenzity obrazu. Počítá se pouze s plochou polygonu.

$$m_{pq} = \iint_{(x,y) \in R} (x - x_0)^p (y - y_0)^q dx dy \quad (4.45)$$



**Obrázek 4.8:** Voronoi diagram 11 bodů v Eukleidovském prostoru, převzato z [6]

Tyto momenty jsou počítány s respektováním souřadnic  $x_0, y_0$  bodu (tokenu), k němuž oblast náleží. Díky tomu jsou oblasti vzájemně porovnatelné napříč celým obrazem. Nižší řády momentů mají dobrou geometrickou interpretaci. Například  $m_{00}$  je plocha polygonu, podíly  $m_{10}/m_{00}$  a  $m_{01}/m_{00}$  ukazují rozdíl souřadnic geometrického středu a příslušného bodu. Momenty  $m_{20}, m_{11}$  a  $m_{02}$  mohou být použity k popisu podlouhlosti a orientace. Momenty vyšších řádů poskytují ještě detailnější popis tvaru (například symetrii). Jednotlivé komponenty příznakového vektoru, vytvořeného na základě popisu Voronoi diagramu, uvádí rovnice 4.46.

$$\begin{aligned}
 f_1 &= m_{00} \\
 f_2 &= \sqrt{\bar{x}^2 + \bar{y}^2} \\
 f_3 &= \operatorname{atan}\left(\frac{\bar{y}}{\bar{x}}\right) \\
 f_4 &= \sqrt{\frac{\sqrt{(m_{20} - m_{02})^2 + 4m_{11}^2}}{m_{20} + m_{02} + \sqrt{(m_{20} - m_{02})^2 + 4m_{11}^2}}} \\
 f_5 &= \operatorname{atan}\left(\frac{2m_{11}}{m_{20} - m_{02}}\right)
 \end{aligned} \tag{4.46}$$

kde  $\bar{x}$  a  $\bar{y}$  jsou souřadnice středu polygonu

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad \bar{y} = \frac{m_{01}}{m_{00}} \tag{4.47}$$

Podrobnějším pohledem na jednotlivé příznaky zjistíme, že  $f_2$  uvádí velikost vektoru mezi tokenem a středem Voronoiovy buňky,  $f_3$  vyjadřuje směr tohoto vektoru,  $f_4$  udává podlouhlost polygonu ( $f_4 = 0$  pro kruh) a  $f_5$  informuje o orientaci hlavní osy.

Segmentace obrazu je prováděna po celých polygonech na základě výše uvedených momentů pomocí pravděpodobnostního klasifikátoru. Navržený postup umožňuje segmentovat obrazy, na jejichž vstupu jsou pouze jednotlivé body. Aby bylo možné metodu využít pro segmentaci textur, je nutné extrahovat bodový obraz jednotlivých tokenů z šedotónového obrazu. K tomu je navržen tento postup:

1. Je aplikován Laplacian of Gaussian (LoG) filtr pro nalezení hran a odstranění šumu. Výsledek takového filtrování je na obrázku 4.9b
2. Jsou zvoleny body, které leží na lokálních maximech intenzit filtrovaného obrazu. Za bod ležící na maximu je považován takový bod, jehož hodnota je vyšší než alespoň šest bodů z jeho osmiokolí. Tím je vytvořen binární obraz, jehož ukázkou je možné vidět na obrázku 4.9c
3. V dalším kroku je použita analýza spojených oblastí. Každý spojitý objekt je dále považován za texturní element a pro potřeby texturní analýzy pomocí Voronoi rozkladu jej lze nahradit jeho geometrickým středem.

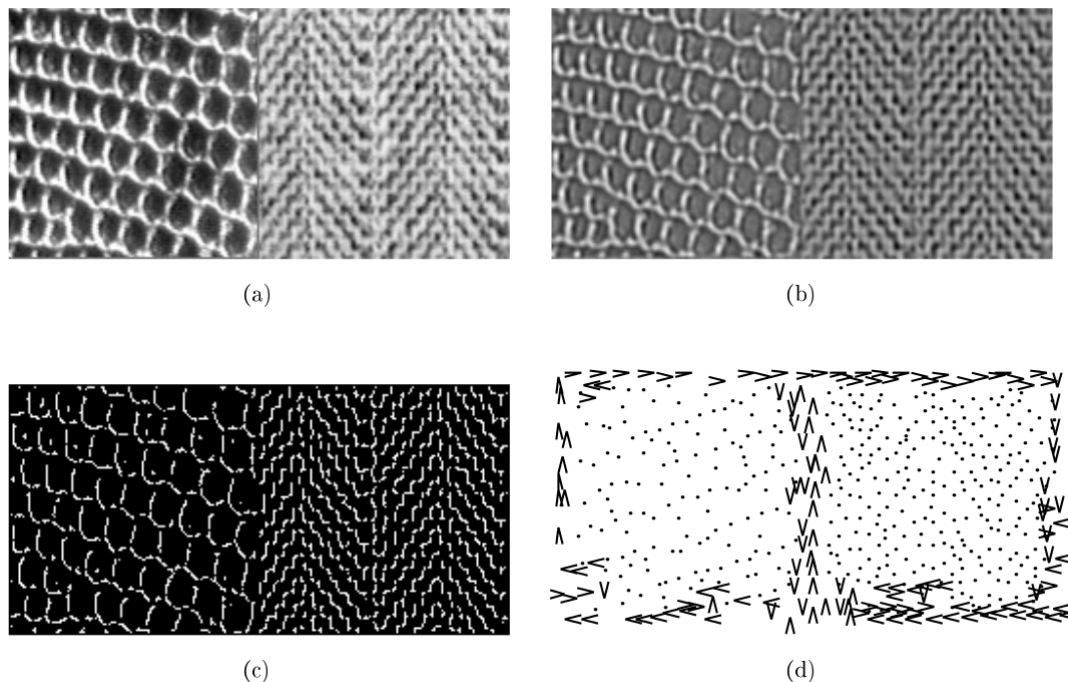
Obrázek 4.9 Ukazuje všechny významné kroky analýzy pomocí rozkladu na Voronoi buňky.

### Syntaktický přístup k popisu textury

Metoda pro segmentaci textur pomocí analýzy Voronoi mozaikování zpracovává informace o texturních elementech statistickým způsobem. Není zde podstatné umístění elementu v texturním obraze ani vzájemná poloha. V řadě úloh však právě tyto vlastnosti mohou být klíčové. Syntaktický přístup tyto vlastnosti umožňuje respektovat. Zpracování obrazu tímto způsobem má dva kroky. Prvním je nalezení jednotlivých texturních elementů, druhým je pak analýza jejich vzájemného rozmístění. Vhodným způsobem analýzy je syntaktická analýza. Ta je podobná analýze řeči. Z rozmístění texturních elementů je sestaven řetězec. V trénovací fázi je z něj odvozena gramatika. Při rozpoznávání je pak zkoumáno, zda neznámý řetězec vyhovuje dané gramatice.

V [112] jsou popsány gramatiky založené na řetězcích primitiv a gramatiky vytvořené na základě grafové reprezentace obrazu. Obrázek 4.10 zobrazuje texturu a graf vytvořený na základě jednotlivých texturních elementů.

Metody tohoto druhu jsou vhodné pro přísně organizované textury. V obrazech z reálného prostředí se často projevuje velká variabilita textur. Ta může být způsobena vadami materiálu, šumem, ale i přirozenými vlastnostmi povrchu. To znemožňuje užití striktních gramatik. Je nutné využívat nedeterministické a stochastické gramatiky. Pro potřeby popisu textur biologického původu není syntaktický popis příliš vhodný. V úlohách, kde je potřeba pracovat s texturami umělého původu, však tento přístup přináší dobré výsledky.



**Obrázek 4.9:** Jednotlivé kroky extrakce příznaků pro segmentaci pomocí Voronoi mozaikování - obrázek (a) vstupní obraz, (b) výstup LoG filtru, (c) nalezené texturní elementy a (d) náhrady elementů body (šipky označují směr hran), převzato z [122]

### 4.1.3 Metody založené na modelech


Metody založené na modelech textur lze využívat jak pro popis textury, tak i pro její vytváření. Myšlenka popisu vychází z představy parametrického modelu pro generování intenzitní funkce. Změnou parametrů takového modelu lze vytvářet různé textury. Popis textury tímto způsobem je v podstatě optimalizační úloha, v níž se snažíme vygenerovat pomocí modelu obraz co nejbližší pozorované textuře.

#### AR modely


Rekurzivní (Autoregressive (AR)) modely vycházejí z předpokladu, že obraz je náhodná proměnná. Pro jednoduchost použijeme jednorozměrný model 4.48 z obrázku 4.11, který je buzen bílým šumem tak, že  $E[\eta(n)] = 0$  a  $E[\eta(n)\eta(n-1)] = \sigma^2\delta(l)$  a  $\delta(l) = 1$  pro  $l = 0$  jinak  $\delta(l) = 0$ . Impulzní funkce  $h(n)$  splňuje podmínku  $\sum_n |h(n)| < \infty$ .

$$I(n) = \sum_{k=0}^p a(k)I(n-k) + \eta(n) \quad (4.48)$$

kde koeficienty  $a(k)$ ,  $k = 1, 2, \dots, p$  jsou parametry systému.



**Obrázek 4.10:** Graf popisující strukturu textury. (a) Textura složená z různých primitiv, (b) graf v překryvu s texturou. Převzato z [112]



**Obrázek 4.11:** Jednorozměrný AR model, převzato z [116]

Odhad parametrů lze stanovit s využitím minimalizace střední kvadratické chyby. Výsledek je naznačen rovnicí 4.49. Další podrobnosti lze vyčíst z [116].

$$Ra_p = r_p \quad (4.49)$$

AR modely jsou zvláštním případem obecnější množiny modelů, které navíc zahrnují nerekurzivní model s klouzavým průměrem (Moving Average (MA)) a jsou známé jako ARMA modely. Ty jsou popsány rovnicí 4.50.

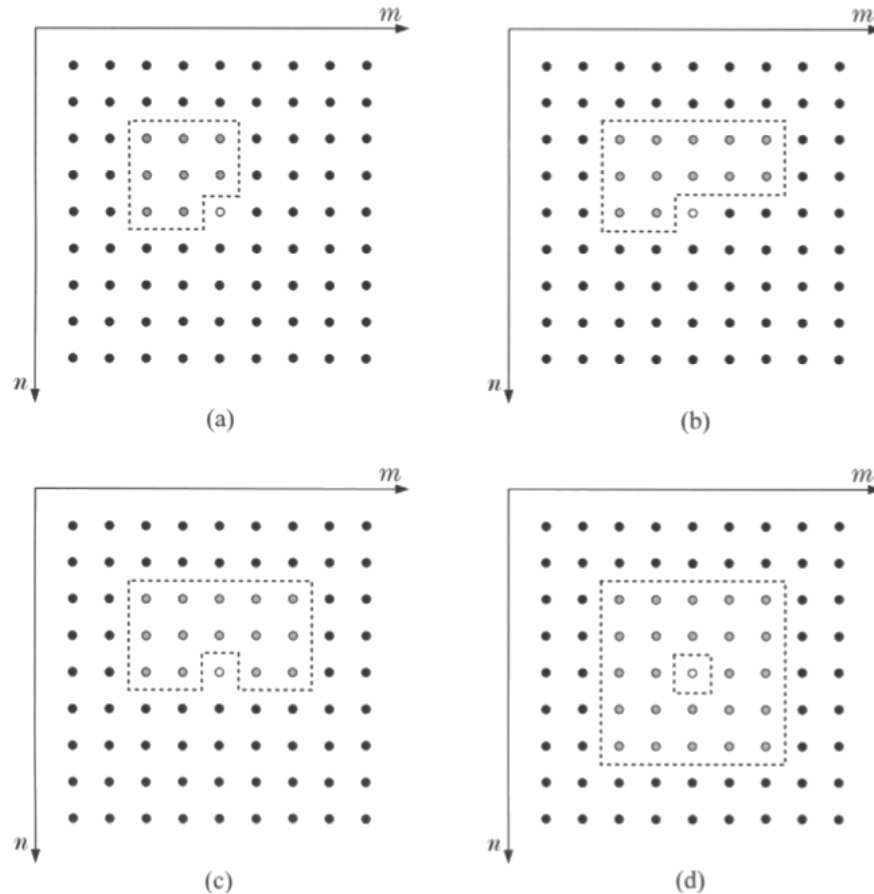
$$i(n) = \sum_{k=1}^p a(k)I(n-k) + \sum_{l=0}^m b(l)\eta(n-l) \quad (4.50)$$

Dvourozměrný AR model obrazu  $I(m, n)$  je dán rovnicemi 4.51 a 4.51

$$\hat{I}(m, n) = \sum_k \sum_l a(k, l)I(m-k, n-l) \quad (k, l) \in W \quad (4.51)$$

kde  $W$  je okolí pixelu.

$$I(m, n) = \hat{I}(m, n) + \eta(m, n) \quad (4.52)$$



**Obrázek 4.12:** Okolí pixelu pro dvojrozměrný odhad. Bíle je označen odhadovaný pixel, šedivě pixely použité pro odhad a černě ostatní pixely. (a) ryze kauzální model, (b) kauzální, (c) polokauzální a (d) nekauzální ,převzato z [116]


Okolí pixelu  $W$  lze definovat řadou způsobů. Odhad může být určen z pixelů jejichž index je menší než index odhadovaného pixelu. Pak hovoříme o ryze kauzálním systému. Pojem kauzality však v dvojrozměrném prostoru bez uvažování času nemá smysl a tudíž lze pro výpočty využívat i jiné typy okolí. Kauzální, polokauzální a nekauzální okolí ukazuje obrázek 4.12.

AR modely mají blízko k Markovským náhodným polím. Myšlenka takových polí byla představena v [74](dalším textem je [57]). Lze ukázat, že každý Gaussovský AR model je Markovské náhodné pole( [131]). Základem takových polí je, že je obraz pro každý pixel rozdělen na tři oblasti. Oblast  $\Omega^+$  představuje „budoucnost“, oblast  $\Omega$  „současnost“ a  $\Omega^-$  „minulost“. Analýze textur pomocí markovských modelů se věnuje článek [23].



### Popis textury pomocí fraktálů

Analýza textur založená na užití fraktálů byla představena v [94]. Byl zde představen soubor funkcí charakterizovaných takzvanou fraktální dimenzí. Fraktální modely typicky souvisejí s metrickými vlastnostmi jako délka nebo povrch oblastí k její jednotkové délce. K hojně užívaným příkladům patří měření délky pobřeží. Při této úloze velmi záleží na měřítku, se kterým je měření prováděno. Předpokládejme, že délku budeme měřit měřidlem o délce 1 km. Stejný úkon provedeme s měřidlem o délce 0,5 km. Je



**Obrázek 4.13:** Tři povrchy s různou fraktální dimenzí  $FD = 2, 1; 2, 5; 2, 9$ . Převzato z [70]

zřejmé, že naměřené délky se budou lišit. Menší měřidlo je schopné postihnout drobnější křivosti hranice. Čím kratší měřidlo použijeme, tím bude naměřená délka větší. Vztah mezi délkou měřidla a naměřenou délkou lze popsat rovnicí:

$$L = cr^{1-D} \quad (4.53)$$

kde  $L$  je naměřená vzdálenost,  $r$  je délka měřidla a  $D$  je fraktální dimenze.

Fraktální popis textur je zpravidla založen na určování fraktální dimenze a měření lankularity (míra vyplnění prostoru fraktálem) k určení drsnosti a zrnitosti z jasového obrazu. Srovnání metody odhadu fraktální dimenze lze najít na obrázku 4.13 demonstruje souvislost růstu fraktální dimenze a hrubosti textury. Při texturní analýze bývá topologická dimenze rovna třem. Dvě představují prostor obrazu a jedna je jasová funkce.

Zajímavou vlastností fraktálního popisu je invariance vůči změně měřítka. Oproti AR modelům a Markovským polím dokáže tento popis lépe postihnout nízké frekvence v texturách.

#### 4.1.4 Metody vycházející ze zpracování signálů

Přístupy popsané v části 4.1.1 pracovaly s obrazem jako s celkem. Statistiky prvního řádu zpracovávaly data jako statistický soubor bez respektování prostorového rozložení jasů. Statistiky druhého řádu však byly schopny vzájemnou polohu pixelů s různým jasnem postihnout. Alternativou k nim jsou metody využívající postupy z oboru zpracování signálů.

#### Lokální lineární transformace

Hojně užívaným přístupem při zpracování signálů je užití lokálních lineárních transformací. Takové transformace pracují s pixelem a jeho okolím. Společným základem všech těchto metod je lineární filtr, který je konvoluován s obrazem. Výstup tohoto filtru je pak nutno interpretovat a kvantifikovat.

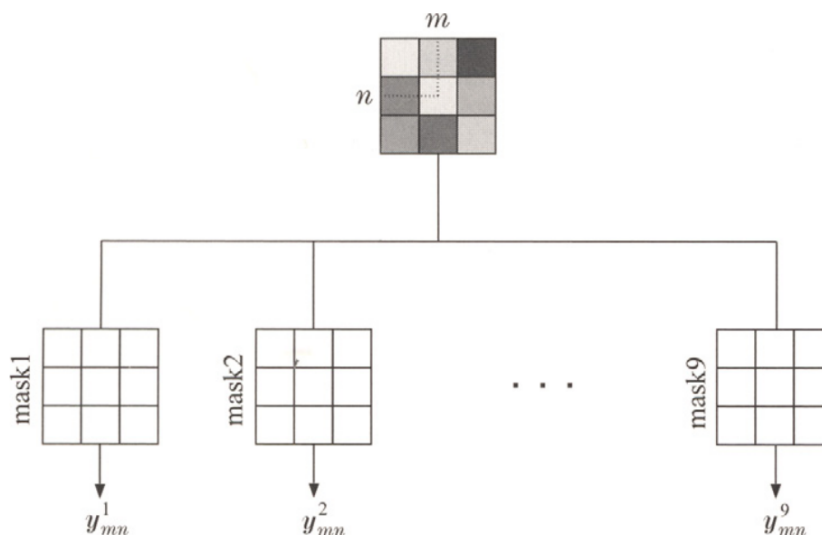
*Popis textury pomocí skupiny lineárních filtrů*

Přístup z části 4.1.2 ukázal základní myšlenku analýzy pomocí hran. Nevýhodou takového přístupu je nerespektování dalších charakteristik textury. S tím se lze vypořádat úpravou a rozšířením systému. Obrázek 4.14 naznačuje vytvoření vícekanálové odezvy  $y_{mn}$  na skupinu lokálních filtrů na okolí  $N \times N$  obrazového bodu o souřadnicích  $(m, n)$ .

Pro potřeby dobrého texturního popisu je potřeba respektovat jasové charakteristiky povrchů, výskyt hran, ale i přítomnost samostatných bodů. Takové filtry navrhuje Laws v článku[71]. Jsou vytvořeny z trojice vektorů

$$\begin{aligned} & [1, 2, 1] \\ & [-1, 0, 1] \\ & [-1, 2, -1] \end{aligned}$$

První vektor odpovídá operátoru lokálního průměrování se zvýrazněným středem, druhý provádí výpočet hran v obraze a třetí zajišťuje detekci bodů. Odvozené filtry jsou uvedeny v 4.54.



**Obrázek 4.14:** Filtrování obrazu s různými maskami a vytvoření vícekanálové odezvy banky filtrů, převzato z [118]

$$\begin{array}{ccc}
 \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} & \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} & \begin{bmatrix} -1 & 2 & -1 \\ -2 & 4 & -2 \\ -1 & 2 & -1 \end{bmatrix} \\
 \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} & \begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix} & \begin{bmatrix} 1 & -2 & 1 \\ 0 & 0 & 0 \\ -1 & 2 & -1 \end{bmatrix} \\
 \begin{bmatrix} -1 & -2 & -1 \\ 2 & 4 & 2 \\ -1 & -2 & -1 \end{bmatrix} & \begin{bmatrix} 1 & 0 & -1 \\ -2 & 0 & 2 \\ 1 & 0 & -1 \end{bmatrix} & \begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix}
 \end{array} \quad (4.54)$$

Konvolucí těchto masek s obrazem je získána vícekanálová odezva skupiny filtrů. Každý kanál zachycuje jinou charakteristiku textury. Pro klasifikaci mohou být použita kritéria stanovená na základě statistik prvního řádu (například rozptyl, šikmost, špičatost ...) pro každý z těchto kanálů. Masky filtrů mohou být stanoveny různým způsobem a mohou mít i větší rozměry než  $3 \times 3$ .

### Frekvenční oblast

Na základech měření ve frekvenční oblasti je založena celá řada metod pro zpracování obrazu. Charakteristické vlastnosti textur jsou provázány s velikostí texturních primitiv. Jemné textury jsou složeny z menších částí, zatímco u hrubých textur je velikost primitiv větší.


Jednou z metod vhodných k hodnocení prostorových frekvencí v obraze je autokorelační funkce. Textura je korelována sama se sebou. Hodnota autokorelační funkce bude periodicky růst a klesat podle velikosti primitiva.

$$C_{ff}(p, q) = \frac{MN}{(M-p)(N-q)} \frac{\sum_{i=1}^{M-p} \sum_{j=1}^{N-q} f(i+p, j+q)}{\sum_{i=1}^M \sum_{j=1}^N f^2(i, j)} \quad (4.55)$$

Výhodou je, že díky algoritmu rychlé Fourierovy transformace (FFT), lze autokorelační funkci vypočítat ve frekvenční oblasti v krátkém čase.

$$C_{ff} = \mathcal{F}^{-1} \{|F|^2\} \quad (4.56)$$

Prostorové frekvence v obraze se rovněž projevují ve spektru. Frekvenční obrazy hrubých textur jsou tvořeny více nízkými kmitočty, u jemných se projevují spíše kmitočty nižší. Je však nezbytné frekvenční obraz správně interpretovat. Po Fourierově transformaci (a příslušném přeskládání obrazu) se nízké frekvence zobrazují do středu spektra, zatímco vysoké jsou situovány dále. Hrany v obraze vytvářejí ve frekvenční oblasti jasné čáry, jdoucí středem obrazu se směrem kolmým na původní hranu. To je důsledkem široké frekvenční odezvy skoků v prostorové oblasti. Obrázek 4.15 nazna-



**Obrázek 4.15:** Filtry pro analýzu ve frekvenční oblasti, (a) kruhový filtr, (b) klínový filtr, převzato z [112]

čuje základní možnosti analýzy. Varianta 4.15a zobrazuje filtr pro podobné frekvence ve všech směrech, obrázek 4.15b ukazuje klínový filtr pro analýzu výskytu hran v určitém směru.

Analýza na základě prostorových frekvencí je dobře známým přístupem, z něhož vychází řada metod. Zůstává však řada problémů. Jedním z nich je například to, že popis takto vzniklý není obecně invariantní vůči jasovým transformacím. Řada jiných metod přináší lepší výsledky.

### Kosinová transformace

Další možnost pro popis textur představuje (diskrétní) kosinová transformace (Discrete Cosine Transform (DCT)). Diskrétní kosinová transformace je podobná Fourierově transformaci (Discrete Fourier Transform (DFT)), na rozdíl od ní však produkuje pouze reálné koeficienty. Její báze funkce nezávisí na zpracovávaném obraze a jsou předem dány. Lze ji snadno zobecnit do více rozměrů a pro dopřednou i zpětnou transformaci existují rychlé algoritmy.

Dopředná kosinová transformace jednorozměrného signálu pro  $k = 0, 1, \dots, N - 1$  je dána následujícím vztahem:

$$y(k) = \alpha(k) \sum_{n=0}^{N-1} x(n) \cos\left(\frac{\pi(2n+1)k}{2N}\right)$$

Zpětná kosinová pro  $n = 0, 1, \dots, N - 1$

$$x(n) = \sum_{k=0}^{N-1} \alpha(k) y(k) \cos\left(\frac{\pi(2n+1)k}{2N}\right)$$

kde

$$\alpha(k) = \begin{cases} \sqrt{\frac{1}{N}}, & k = 0 \\ \sqrt{\frac{2}{N}}, & k \neq 0 \end{cases}$$

Pro transformaci obrazu lze kromě DFT a DCT využívat i Sinovou transformaci (DST), Hadamardovu transformaci a transformaci Krahunen-Loeve(KLT). Poslední jmenovaná se od ostatních liší tím, že má báze závislé na datech a nelze je tedy předpokládat dopředu. Discrete Sine Transform (DST) a DCT mají lepší schopnost komprimace informace než DFT, což dokládá obrázek 4.16. Další informace o zmiňovaných transformacích lze dohledat v knize [97].

### Gaborovy filtry a Wavelety

Wavelet analýza využívá myšlenku více-měřítkové analýzy. Pro zpracování signálu je využíváno okénko, jehož šířka se mění podle frekvence. Pokud je oknem Gaussián, hovoříme o Gaborově filtru.

Gaborův filtr je lineární filtr hojně používaný pro zpracování signálů ([41]). Daugman v článku [25] poukázal na souvislost mezi Gaborovými filtry a vizuálním kortexem primátů. Myšlenka použití těchto filtrů pro texturní analýzu byla navržena v [124]. Jádro filtru je dáno součinem Gaussovského okna a komplexní exponenciály 4.57. Obrázek 4.17 zobrazuje ukázkou takového jádra.

$$h(x, y) = g'(x, y) \exp(j(\omega_x x + \omega_y y)) \quad (4.57)$$

kde

$$g'(x, y) = \frac{1}{\sigma^2} g\left(\frac{x'}{\lambda\sigma}, \frac{y'}{\sigma}\right), \quad (4.58)$$



**Obrázek 4.16:** Transformace obrázku pomocí DFT, DST a DCT po směru hodinových ručiček, převzato z [116]

a

$$\begin{aligned}x' &= x \cos \theta + y \sin \theta \\y' &= -x \sin \theta + y \cos \theta\end{aligned}\quad (4.59)$$


$$g(x, y) = \frac{1}{2\pi} \exp\left(-\frac{x^2 + y^2}{2}\right) \quad (4.60)$$

Okno  $g'$  4.58 je verzí Gaussiánu (rovnice 4.60), který má změněné měřítko a je natočen o úhel  $\theta$ . Měřítko je dáno parametrem  $\sigma$ , parametr  $\lambda$  udává poměr zvětšení. Filtr tím nemusí být symetrický. Orientace filtru je volena zpravidla podle parametrů komplexní exponenciály. Úhlová rychlost vlny v exponenciále je


$$\omega = \sqrt{\omega_x^2 + \omega_y^2} \quad (4.61)$$

Orientace je pak volena

$$\theta = \arctan \frac{\omega_y}{\omega_x} \quad (4.62)$$




(a)



(b)

**Obrázek 4.17:** Reálná složka jádra Gaborova filtru. (a) Vyjádření hodnot filtru ja- sem, (b) zobrazení pomocí třetího rozměru


Změnou parametrů  $\lambda$ ,  $\sigma$ ,  $\omega$  a  $\theta$  jsou měněny základní vlastnosti filtru (jako např. šířka pásma). Odezva je často počítána pomocí konvoluce se zkoumaným obrazem, ale lze ji počítat pouze pro konkrétní bod. Filtr pak poskytuje informaci o výskytu vlny o frekvenci  $\omega$  a směru  $\theta$ . Odezvu filtru ilustruje obrázek 4.18.



**Obrázek 4.18:** Odezva Gaborova filtru. (a) Původní obraz, (b) odezva reálné části filtru, převzato z [96]

Pro klasifikaci textur je zpravidla užívána skupina (banka) filtrů s různými frekvencemi a různým natočením. Je tak vytvořena vícekanálová odezva. Textura je pak charakterizována amplitudami odezvy různých filtrů. Takový přístup je použit v [11]. V [56] je použita skupina Gaborových filtrů pro segmentaci textur bez učitele.

Složitým problémem v úlohách segmentace je přesná klasifikace v místě styku textur. Každý filtr totiž pracuje s nějakým okolím pixelu a odezvy jednotlivých filtrů na hranicích nutně počítají s oběma texturami. Částečně je možné se s tímto problémem vypořádat výpočtem odezvy po polorovinách. Každý filtr z banky je před výpočtem rozdělen přímkou  $p$  (4.19a) a odezva je počítána pro každou polovinu zvlášť. Provedeno je to jednoduše nastavením jedné poloviny konvolučního jádra na nulu 4.19a. Například




**Obrázek 4.19:** Dvoustranná texturní analýza

pro dvojici přímk, kdy je jedna vodorovná a druhá svislá, získáme odezvy pro levé,



pravé, horní a dolní okolí zkoumaného bodu. Uvnitř kompaktní oblasti bude odezva opačných polorovin stejná. Na rozhraní se však bude odlišovat. Přístup, který využívá dvoustrannou konvoluci je použit například v článku [132]. Autoři používají tvarový model ledviny a na okrajích zkoumají texturu vně tvaru a uvnitř. Podle naměřené míry podobnosti je model iterativně deformován. Podobnost je počítána na základě vícesložkového pravděpodobnostního modelu.



**Obrázek 4.20:** Podobnost syntetického texturního obrazu. Vysoký jas znamená velké rozdíly mezi trénovací texturou a obrazem. (a) Syntetický obraz. (b) Trénovací textura. (c) Podobnost vytvořená běžným způsobem. (d-f) Podobnosti pro tři různé směry, pomocí dvoustranné konvoluční strategie. Obrázek je převzat z [132]

Úvod do problematiky Gaborových filtrů lze nalézt v [84]. Srovnání různých příznaků pro popis textur, které vycházejí z Gaborových filtrů, je v článku [47].

#### 4.1.5 Zhodnocení metod pro popis textur

Srovnání řady přístupů pro popis textur je v článku [21]. Nejlepších výsledků zde dosahují metody využívající matici sousednosti. Slabých výsledků bylo dosaženo s využitím metod, které využívají opakování jasů. Metody pro analýzu s maticí sousednosti byly dobře hodnoceny ve srovnání [107], kde rovněž vynikla Lawsova metoda, jež využívá skupiny lineárních filtrů. Velmi dobrých výsledků dosahují metody využívající Gaborovy filtry. Jejich slabinou je však výpočetní náročnost. Velmi populární metoda poslední

doby je LBP, která dosahuje dobrých výsledků ([87]) a je výpočetní nenáročná.

Široce platné porovnání různých texturních metod není kvůli chybějícímu univerzálně uznávanému hodnoticímu prostředku snadné. Nelze tak vzájemně porovnávat výsledky různých hodnocení. Výsledky jednotlivých metod v konkrétních úlohách jsou velice závislé na charakteru dat. To ovlivňuje výběr vhodné metody a znesnadňuje obecné hodnocení. Často užívaným datasetem, díky kterému je možné porovnávat výsledky alespoň částečně, je fotografické album [17]. Svetlana Lazebnik používá v článku [72] volně dostupnou databázi tisíce obrázků, která obsahuje 40 vzorků pro každou z 25 textur. Povrchy jsou zachyceny z různých úhlů. Další dostupnou databází je Columbia-Utrecht Reflectance and Texture Database (CURET) ([24]). Jedním z příkladů systémů pro obecné hodnocení například Outex ([88]).

## 4.2 Strojová segmentace objemových obrazových dat

Segmentační metody mohou být rozděleny do tří skupin. První vychází z globální znalosti o obraze nebo jeho částech. Taková znalost může být reprezentována například histogramem. V praxi například víme, že pixely reprezentující určitý objekt, mají určitý jas. Hranově založené přístupy reprezentují druhou skupinu metod. Využívají nespojitost v obraze, které bývají na okrajích objektů. Třetí skupina vychází z analýzy oblasti. Zde se naopak vychází z jisté homogenity uvnitř objektů. Druhá a třetí skupina řeší duální problém. Každá oblast může být reprezentována svojí hranicí a každá uzavřená hranice popisuje oblast.

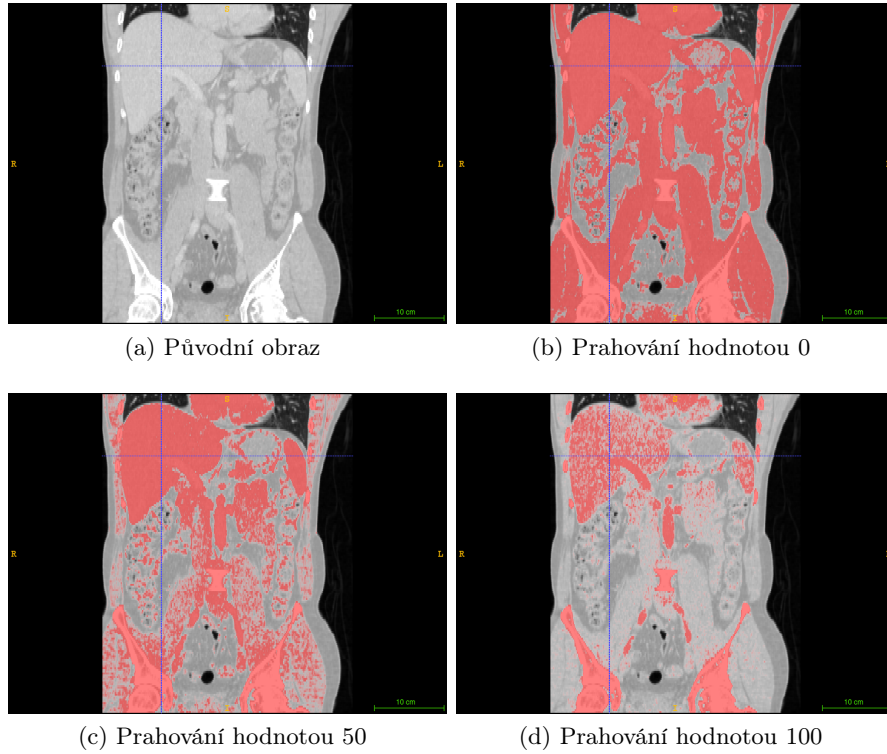
### 4.2.1 Metody vycházející z globální znalosti o obraze

Nejběžněji užívanou metodou, která spadá do kategorie segmentačních metod, vycházejících z globální znalosti o obraze, je prahování. Ústředím bodem metody je předpoklad, že každý objekt obrazu má jiný jas. Pro případ rozdělení obrazu na popředí a pozadí je zvolen určitý práh. Pixely, které mají jas nad tímto prahem, patří do jedné třídy, zatímco zbylé patří do druhé třídy. Na obrázku 4.21 je zobrazeno prahování s různou úrovní prahu.

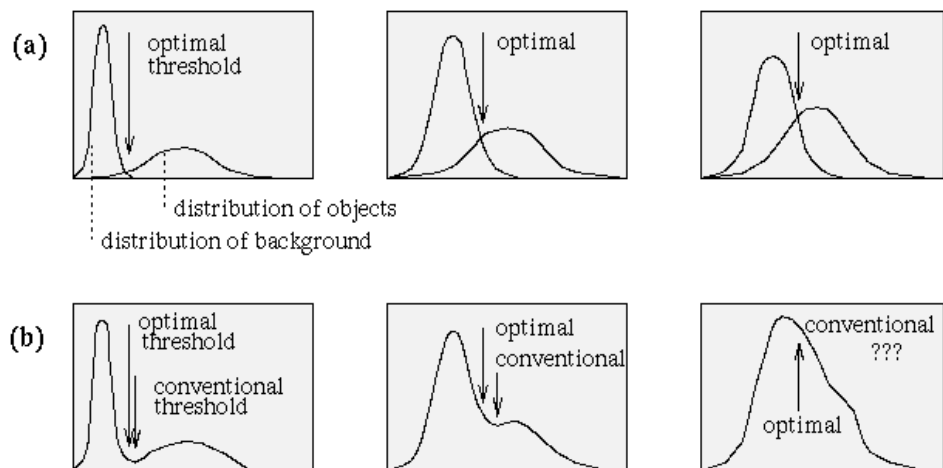
Volbu prahu je možné uskutečnit různými způsoby. Jedním z používaných řešení pro obrazy s bimodálním histogramem (dvě výrazně oddělené třídy) je volba prahu v lokálním minimu. Obrázek 4.22 ukazuje histogram vzniklý složením dvou objektů, které jsou dány normálním rozložením. Problém vzniká u posledního případu, kdy v histogramu nevznikne žádný lokální extrém. Řešením této situace je využití optimální volby prahu. Toto řešení předpokládá, že objekty jsou dány normálním rozložením, snaží se iterativně odhadnout jeho parametry a na základě jejich znalosti volí práh. Na již zmínovaném obrázku jsou porovnány výsledky volby prahu v lokálním minimu a optimální prahování. Podrobnější informace lze nalézt v článku [90].

Existuje celá řada modifikací prahování (prahování více prahy, lokální prahování atd.). Srovnání různých přístupů je možné najít v [105].

## 4.2 Strojová segmentace objemových obrazových dat




**Obrázek 4.21:** Segmentace prahováním: (a) Původní obraz na rozsahu jasů -1000 až +1000. Obrázek (b), (c), (d) zobrazují výsledky s různou hodnotou prahu.




**Obrázek 4.22:** Optimální prahování pro dva objekty s normálním rozložením. (a) Hustotní funkce původních objektů. (b) Histogram daný součtem původních objektů s naznačenou hodnotou prahu v minimu (Conventional) a optimálním prahem (Optimal). Převzato z [112]

### 4.2.2 Hranově založené přístupy k segmentaci

Hranově založené přístupy vycházejí z detekce lokálních nespojitostí v obraze. Častým problémem těchto metod je šum v obraze. Příkladem jednoduchého přístupu je prahování hranového obrazu. Klíčovým problémem je vytvoření uzavřené hranice, která popisuje okraj segmentovaného objektu. Zde se uplatňují nejrůznější algoritmy pro sledování hranice. Ty se nezbytně musejí vypořádat se s nesouvislostí hranice atd. Obrázek



(a) Cannyho hranový detektor



(b) Sobelův hranový detektor

**Obrázek 4.23:** Segmentace založená na hranování. Je možné srovnat výstupy dvou odlišných hranových detektorů

4.23 zobrazuje výstup dvojice hranových detektorů - Sobelova a Cannyho ([18]). Jedním z problémů hranového přístupu k segmentaci je vícenásobná odezva hran. To dokumentuje i tento obrázek.

Pokud je v obraze objekt známého tvaru, je možné využít Houghovu transformaci. Metoda byla užita v [31] pro nalezení přímků v obraze. Lze ji však zobecnit i na další tvary. V metodě je naprahaný hranový obraz převeden do parametrické prostoru, který popisuje hledaný tvar. V tomto prostoru je pak daný objekt hledán.

### 4.2.3 Oblastně založené přístupy k segmentaci

Oblastní přístup k segmentaci vytváří objekty na základě analýzy intenzit oblastí. Typickým představitelem metod tohoto typu je spojování oblastí (region growing). Zpravidla je měřena homogenita, která je důležitou vlastností spojitých oblastí. Metoda spojuje dvě oblasti v případě, že výsledná oblast zůstane homogenní. Výhodou je velká robustnost při vysoké úrovni šumu v obraze. Obdobou této metody je štěpení oblastí (region merging). Zde dochází k dělení oblasti, dokud jednotlivé části nesplní kritérium homogenity. Metody nejsou duální. Jejich kombinací je metoda štěpení a spojování (split and merge). Podrobnosti je možné najít v [112].

### 4.2.4 Active Contour Model

Různé přístupy k segmentaci zmíněné v předchozím textu mohou dobře sloužit v jednoduchých úlohách. Ve složitých případech, kde například dochází ke změně osvětlení snímané scény, poskytují tyto metody chabé výsledky. Prahování, segmentace na základě hranování a oblastní přístupy selhávají například kvůli velké míře šumu. Z těchto důvodů byla vyvinuta řada dalších metod, které některé nedostatky odstraňují. Většinou si tyto metody zachovávají nějaký rys základních přístupů, případně je určitým způsobem kombinují.

Jedním ze směrů segmentace jsou metody založené na numerickém řešení diferenciálních rovnic. Základní myšlenkou je upravovat inicializační křivku s cílem nalezení nejmenší hodnoty váhové funkce. Takový způsob však nezaručuje nalezení globálního minima zvoleného kritéria. Známým přístupem, který tento princip využívá, jsou aktivní křivky (Active Contour Model (ACM)), které jsou někdy nazývány „snakes“ [67].


$$E_{snake}^* = \int_0^1 E_{snake}(\mathbf{v}(s)) ds = \int_0^1 \{[E_{internal}(\mathbf{v}(s))] + [E_{image}(\mathbf{v}(s))] + [E_{con}(\mathbf{v}(s))]\} ds \quad (4.63)$$

Obrázek 4.24 ilustruje jejich fungování.

Obor segmentace obrazu zahrnuje široké spektrum metod, které jsou často specifické pro určitý druh úlohy. Vytvoření vyčerpávajícího souhrnu informací o metodách segmentace, které jsou využívány při zpracování obrazu. Nastíněny byly jen základní přístupy. Podrobnější informace lze dohledat například v knize [106] nebo [112]. V dalším textu bude čtenář seznámen s přehledem používaných metod pro potřeby segmentace jater, cév a dalších anatomických celků, které mohou mít vazbu na analýzu parenchymů.

### 4.2.5 Graph-Cut

Myšlenka řezu grafu byla v oboru počítačového vidění poprvé použita v článku [46], ve kterém je představena metoda pro segmentaci binárního obrazu. V dalších článcích [13] a [14] je popsána segmentace v N-dimenzionálním prostoru prostřednictvím optimalizovaných algoritmů.



**Obrázek 4.24:** Průběh segmentace pomocí Active Contour Model. Modrým odstínem je označena předvybraná oblast přípustná pro segmentaci, červeným je znázorněn průběžný stav segmentace

Základní myšlenkou segmentace pomocí metody Graph-Cut (GC) je převedení úlohy na úlohu hledání minimálního řezu grafu. Řez grafu  $G$  je množina hran  $A$  s vlastností, že graf  $G - A$  (vzniklý oddělením hran  $A$  z grafu  $G$ ) je nesouvislý, ale přitom žádná vlastní podmnožina množiny  $A$  tuto vlastnost nemá (viz 4.25c). Minimálním řezem je takový řez, kde součet ohodnocení hran je nejmenší. V prvním kroku jsou obrazová data převedena na graf. Minimální řez takového grafu pak minimalizuje kritériální funkci, jejíž obecný tvar je:

$$C(f) = C_{\text{data}}(f) + C_{\text{hladkost}}(f) \quad (4.64)$$

Celková hodnota kritéria  $C(f)$  pro danou segmentaci  $f$  je dána součtem příspěvku z vlastností oblastních  $C_{\text{data}}(f)$  a hranových  $C_{\text{hladkost}}(f)$ .

Nyní zařadíme každý pixel  $i_k$  do třídy  $L_k \in \{obj, bgd\}$ , kde  $obj$  reprezentuje objekt a  $bgd$  představuje pozadí. Zařazení všech pixelů do třídy  $L = (L_1, L_2, \dots, L_{|I|})$  definuje výslednou segmentaci ([112]). Konkrétní kritériální funkce může být definována pomocí vážené kombinace obou příspěvků  $R(L)$  a  $B(L)$ , které popisují oblastní a krajové vlastnosti segmentace.

$$C(L) = \lambda R(L) + B(L) \quad (4.65)$$

## 4.2 Strojová segmentace objemových obrazových dat

kde

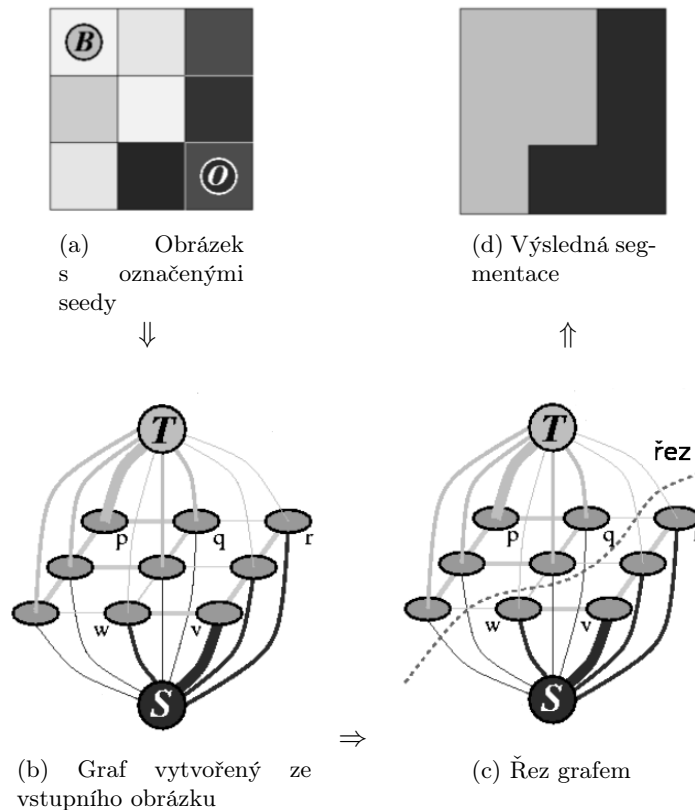
$$R(L) = \sum_{p \in I} R_p(L_p) \quad (4.66)$$

$$B(L) = \sum_{(p,q) \in N} B_{(p,q)} \delta(L_p, L_q) \quad (4.67)$$

a

$$\delta(L_p, L_q) = \begin{cases} 1 & \text{pokud } L_p \neq L_q \\ 0 & \text{jinak} \end{cases} \quad (4.68)$$

$\lambda$  je váhový koeficient vážící význam oblastní a okrajové složky kriteriální funkce.  $I$  označuje obrazová data,  $N$  znamená okolí pixelu (8-okolí, 4-okolí). Část  $R_p(obj)$  lze chápat jako cenu spojenou se zaklasifikováním pixelu  $p$  jako objektu a  $R_p(bgd)$  může být interpretováno jako cena za zařazení stejného pixelu k pozadí.  $B_{(p,q)}$  je cena za hranici mezi pixelem  $p$  a  $q$ . Její hodnota by měla být velká, pokud oba pixely náleží popředí nebo pozadí. Malých hodnot by měla cena nabývat v případech, kdy jeden pixel náleží popředí a druhý pozadí.



**Obrázek 4.25:** Průběh segmentace pomocí metody Graph-Cut, převzato z [13]

## 4.2 Strojová segmentace objemových obrazových dat

Hrana	Váha	
$(p, q)$	$B_{(p,q)}$	pro $(p, q) \in N$
$(s, p)$	$\lambda R_p(bgd)$	pro $p \in I, P \notin (O \cup B)$
	$K$	pro $p \in O$
	$0$	pro $p \in B$
$(p, t)$	$\lambda R_p(obj)$	pro $p \in I, P \notin (O \cup B)$
	$0$	pro $p \in O$
	$K$	pro $p \in B$

**Tabulka 4.3:** Váhy jednotlivých typů hran při konstrukci grafu pro segmentaci pomocí Grap-Cut

Segmentační metoda Graph-Cut umožňuje využívat měkká a pevná omezení. Měkké omezení uvažuje určitou míru příslušnosti k objektu nebo pozadí. Pevné omezení je využíváno v situaci, kdy chceme nějaký pixel označit jako popředí nebo pozadí. To lze využít při interaktivní segmentaci. Obrázek 4.25a znázorňuje malý obrázek s pevným omezením.

Graf je z obrazu tvořen následujícím způsobem. Obsahuje množství uzlů, které odpovídá počtu pixelů v obrázku. K nim jsou přidány dva zvláštní uzly  $s$  a  $t$ , které reprezentují popředí a pozadí. Takový graf je ukázán na obrázku 4.25b. Graf obsahuje dva typy ohodnocených hran – T-linky a N-linky. Hrany mezi sousedními pixely jsou nazývány N-Linky a jsou spojeny s hranovou energií. T-linky jsou hrany mezi každým pixelem a uzlem  $s$  a  $t$ . Odpovídají energii odvozené z oblastních vlastností obrazu. Tabulka 4.3 uvádí jak nastavit váhy různých typů hran. Rovnice 4.69 uvádí výpočet  $K$ . To představuje hodnotu tak velkou, aby v ní nikdy nedošlo k saturaci při hledání minima kritériální funkce.

$$K = 1 + \max_{p \in I} \sum_{q: (p,q) \in N} B_{(p,q)} \quad (4.69)$$

Konkrétní způsob volby hodnot jednotlivých vah není pevně dán. Pro případy, kdy je jas objektu a pozadí modelován pravděpodobnostním modelem lze volit váhy například jako v [14].

$$\begin{aligned} R_p(obj) &= -\ln P(I_p|O) \\ R_p(bgd) &= -\ln P(I_p|B) \end{aligned} \quad (4.70)$$

$$B(p, q) = \exp\left(-\frac{(I_p - I_q)^2}{2\sigma^2}\right) \frac{1}{\|p, q\|}$$

Kde  $P(I|O)$  a  $P(I|B)$  reprezentují míru věrohodnosti, že pixel náleží objektu, nebo pozadí. Výraz  $\|p, q\|$  znamená vzdálenost mezi pixely a  $\sigma^2$  představuje očekávaný rozptyl jasových hodnot.

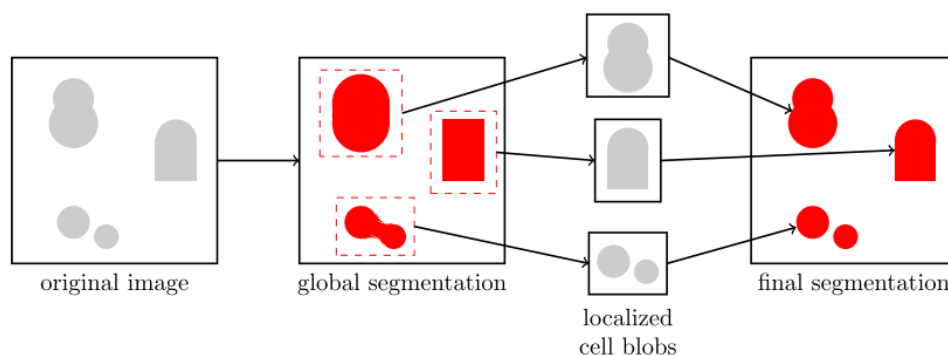
Problém minimálního řezu grafem je duální k problému maximálního toku. Jsou mezi sebou převoditelné. Algoritmy řešení této úlohy mohou být rozděleny do dvou



skupin. Jednou z nich jsou metody typu *push relabel*, druhou je *augmenting path*. Popis a srovnání různých algoritmů lze nalézt v [13].

Segmentace metodou Graph-Cut patří v současné době mezi velmi oblíbené nástroje počítačového vidění. Její výhodou je možnost obecného využití v N-D prostoru (viz [12]). Při vhodném návrhu kriteriální funkce lze nalézt její globální minimum. U dalších segmentačních metod je často velmi obtížné nějakou kriteriální funkci stanovit a výsledky jsou často globálnímu optimu velmi vzdáleny.

### Rozšíření původní metody Graph-Cut



**Obrázek 4.26:** Princip víceměřítkové segmentace dle [65]. Na hrubém měřítku jsou nalezeny pravoúhlé regiony, které jsou nezávisle segmentovány podrobněji

Za účelem snížení výpočetních nároků byla Kangem a Wanem navržena segmentační metoda pro mikroskopii světlého pole (bright-field), která byla popsána v článku [65]. V tomto případě jsou na základě Bhattacharyya vzdálenosti určeny pravoúhlé oblasti pro zkoumání ve větším měřítku. Pro tyto zvolené oblasti je pak spuštěn lokální výpočet Graph-Cut a výsledná data jsou pak přenesena zpět do celkového obrazu.

## 5

# Makroskopický tvarový model parenchymatózních orgánů

Vytváření modelu jater na makroskopické úrovni spočívá ve zkoumání klinicky dostupných dat a s klinicky uplatnitelnými výsledky. Základním krokem je vymezení objemu parenchymu s deskripcí tvaru a umístění jeho částí vzhledem k ostatním anatomickým strukturám těla. V klinické praxi to poskytuje odpovědi na otázky týkající se zejména velikosti funkční tkáně orgánu. Význam má však řešení této úlohy i pro vědecké zkoumání jater, neboť je základem pro zkoumání hlubších zákonitostí perfuze jaterního lalůčku.

Z pohledu počítačového vidění se v zásadě jedná o segmentační úlohu. Ta je prováděna nad trojrozměrnými obrazovými daty, které pocházejí zpravidla z výpočetní tomografie nebo z magnetické rezonance. Metody, které jsou v současnosti využívány na radiologických odděleních našich nemocnic pro odhad velikosti jater, zpravidla kombinují jednoduché segmentační metody s manuálním označováním cílového objemu. Tento proces je časově velmi náročný a klade si vysoké požadavky na pozornost obsluhy. Dalším rysem je velká míra závislosti výsledku na osobě uživatele. Snímky z trojrozměrných zobrazovacích metod mají omezenou rozlišovací schopnost a vzniká zde určitý prostor, ve kterém není možné objektivně rozhodovat, zda tkáň k cílovému objemu náleží, nebo nikoliv. Každý posuzovatel si pak snímek může vykládat mírně odlišným způsobem. Žádné dvě segmentace expertů tak nejsou zcela totožné.

Naším cílem je tedy v této kapitole navrhnout stroj, který bude schopen snížit mentální zátěž obsluhy a snížit čas potřebný k provedení volumetrie jaterního parenchymu. Navržený postup však musí umožňovat dostatečnou měrou ovlivňovat výsledek měření, avšak musí být málo citlivý na nepřesné zadávání vstupů. Díky tomu bude minimalizován vliv osobnosti uživatele na výsledek volumetrie. S ohledem na lidskou interaktivitu je důležité provádět zpracování mezi interaktivními kroky dostatečně rychle.

### 5.1 Odhad velikosti jater

Znalost velikosti jaterního parenchymu je základní informací v průběhu diagnostického procesu. Pro odhad velikosti jaterního parenchymu lze použít řadu metod. V následu-

jícím textu budou některé z nich představeny.

### 5.1.1 Odhad objemu jater na základě plochy těla

Článek [127] ukazuje souvislost mezi velikostí jaterního parenchymu  $LV[ml]$  a koeficientem  $BSA[m^2]$  (Body Surface Area), který představuje velikost povrchu těla. Odhad objemu jater dospělého a dětí nad 15 kg je vyjádřen takto:

$$LV = 706.2 \times BSA + 2.4 \quad (5.1)$$

$BSA$  lze vypočítat pomocí výšky ( $BH[cm]$ ) a váhy ( $BW[kg]$ ) zkoumané osoby dosazením do DuBoisova vyjádření [30] následujícím způsobem:

$$BSA = BW^{0.425} \times BH^{0.725} \times 0.007184 \quad (5.2)$$


Nevýhodou metody je určitá plochost poskytované informace. Kvalita odhadu má pochopitelně svá omezení a nerespektuje dostatečně individuální odlišnosti v lidské anatomii. K dispozici máme jen číselné vyjádření objemu, které je například pro potřeby predikce velikosti resektátu nedostatečné. Tam je nezbytná širší informace, zahrnující trojrozměrný popis tvaru orgánu. Zde již nelze vystačit s jednoduchým měřením a vážením pacienta. Pro získání patřičné odpovědi je v moderní medicíně využíváno trojrozměrných zobrazovacích metod.

Vymezení oblasti, kde se nalézají zájmové útvary v objemových datech (játra, srdce, cévy), je nazýváno segmentací. Ta je obvykle jedním z nejdůležitějších kroků, které vedou k analýze zpracovávaných obrazových dat. Jejím hlavním cílem je rozdělení obrazu do částí, které mají silnou vazbu k objektům a oblastem reálného světa zachyceného v obraze ([112]). Jejím cílem je tedy rozdělení obrazových bodů do dvou či více tříd, které odpovídají objektům. Často jsou těmito třídami „objekt“ a „pozadí“.

Při popisu algoritmu vzniká problém s přetížením pojmu „segmentace“. Lékaři mu v souvislosti s prací na játrech rozumí jako anatomickému rozdělení jater na segmenty dle Couinauda. V tomto textu se však přidržíme chápání termínu dle oboru počítačového vidění.

### 5.1.2 Manuální volumetrie


V současnosti je základním nástrojem v klinickém prostředí segmentace pomocí ručního označování okraje segmentace v každém řezu. Tato procedura je náročná na čas, ale vyžaduje i velké soustředění operátora. Příkladem takového nástroje je Syngo Volume. Obrázek 5.1 dokumentuje proces návrhu okraje segmentace, který je obsluhou zadáván prostřednictvím myši. Nedostatky tvaru jsou následně upravovány pomocí kruhového „hladítka“. K dispozici jsou rovněž nejrůznější poloautomatické nástroje založené například kombinací prahování a manuálního vymezení oblasti. Ty snižují zátěž obsluhy, ale jsou použitelné jen pro omezenou množinu dat. Důvodem je vysoká rozmanitost porizovaných CT a Magnetic Resonance Imaging (MRI) snímků. Densita jaterního parenchymu kolísá v závislosti na koncentraci kontrastní látky v orgánu. Ta je dána uplynulým



**Obrázek 5.1:** Manuální segmentace pomocí aplikace Syngo Volume

časem od podání kontrastní látky, ale i individuálními charakteristikami oběhového systému vyšetřované osoby. Dalšími zdroji poruch automatických metod jsou léze a jiné objekty, které mají výrazně odlišnou densitu, než zbytek jater.

K úspěšnému provedení segmentace je zpravidla nezbytná vyšší znalost okolností konkrétní úlohy. Na druhou stranu existuje celá řada případů, které lze uspokojivě řešit nízkourovňovým zpracováním.



**Obrázek 5.2:** Ruční segmentace kombinovaná s prahováním

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

Z dlouhodobých pozorování a diskuzí s experty z oboru radiologie vzešlo několik požadavků na cílenou podobu segmentačního procesu. Kromě potřeby dobře segmentovat cílové objemy je vyžadována rozumná podoba uživatelské interakce. Ta musí poskytovat komfortní možnost ovládání segmentačního algoritmu s možností velkou měrou ovlivňovat výsledek. Zároveň však vhodně navržená interaktivita nevyžadovala vysokou soustředěnost uživatele po dlouhou dobu.

Pro potřeby segmentace lze vycházet z některých apriorních informací o parenchymatózních orgánech.

- Parenchymatózní orgány se svým objemem řadí mezi velké vnitřní orgány lidského těla. Játra jsou například v tomto ohledu orgánem největším.
- Obraz parenchymu na tomografických vyšetřeních je homogenní. Lokální jasové odchylky jsou způsobeny zejména cévním systémem a patologickými změnami orgánu.
- Orgány jsou uloženy v břišní dutině. Jejich poloha vzhledem k ostatním tkáním je anatomicky popsána a nemění se.
- Při vyšetření výpočetní tomografií se denzita parenchymu pohybuje v definovaném rozmezí. Globální změny jasu dány časem mezi podáním kontrastní látky a tělesnými parametry pacienta, jež jsou predikovatelné pouze částečně.
- Ve vyšetřeních magnetickou rezonancí nelze vycházet z jasových charakteristik. Ty jsou dány parametry vyšetření a prudce ovlivňují výsledný jas jednotlivých struktur.

Vzhledem k výše zmíněnému jsme se rozhodli vytvořit obecný nástroj pro segmentaci orgánů břišní dutiny. K řešení této úlohy bývá běžně používána informace o intenzitě obrazu. V našem případě byla množina informací využívaných pro zpracování vyhodnocování dat rozšířena. Pro vylepšení možností stávajících segmentačních metod byl zkonstruován nový příznakový vektor, který se neomezuje na intenzitu obrazu, ale využívá i data o umístění jednotlivých voxelů uvnitř těla.

### 5.2.1 Určení polohy v těle na základě segmentace základních anatomických struktur

Jednou z informací, kterou využíváme v našem přístupu je informace o umístění hledaného objektu v anatomickém kontextu. Byl vytvořen navigační systém, který na základě segmentace základních struktur poskytuje informace o poloze uvnitř břišní a hrudní dutiny na základě dat z výpočetní tomografie. Vychází se z několika dobře splnitelných předpokladů:

- Pacient je umístěn souběžně s jednou z hlavních os snímků.

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu


- Je známa orientace pacienta (v které ose pacient leží a kde má hlavu).
- Snímky zachycují oblast trupu.

Při určování polohy uvnitř těla je nutné nalézt takové tkáně, které se budou objevovat ve všech hodnocených datech a bude je možné najít dostatečně robustně. Mezi základní vyhledávané prvky tkáně bylo vybráno jádro kosterní soustavy, hranice mezi břišní a hrudní dutinou a povrch těla. Dalším aspektem, který je uvažován je možnost zobecnit metodu pro použití na experimentálních zvířatech. Je tedy nutno využívat anatomické struktury, využitelné i u prasete domácího, které je pro experimentální medicínu často využíváno.

### Segmentace jádra kosterní soustavy

Segmentace jádra kosterní soustavy je prováděna kombinací filtrace a prahování. Parametry jednotlivých kroků byly zvoleny experimentálně. Na data z výpočetní tomografie je aplikována filtrace Gaussiánem, jehož směrodatná odchylka ve směru souběžném s osou těla je 30 mm. Ve směrech kolmých je pak směrodatná odchylka 7,5 mm. Takovéto nastavení zachovává vysoce denzitní tkáně, které jsou orientovány v ose těla. Naopak tkáně s menší velikostí a odlišnou orientací jsou ve výstupu filtru potlačeny. Takto zpracovaný obraz je pak prahování s hodnotou 200 HU.

Ve výsledném obraze tak prakticky zůstávají středové oblasti páteře (viz obrázek 5.3). V některých případech se pak ve výstupu objevují i oblasti pánve a kyčelní klouby se stehenními kostmi. Všechny tyto části jsou umístěny souměrně k ose těla. Na zá-



**Obrázek 5.3:** Segmentace jádra kosterní soustavy. To je označeno modrou barvou

kladě takto získaného objemu je informace získána souřadnice osy kostry, kterou pro jednoduchost budeme dále nazývat osou páteře. Tu lze využít jako první opěrný bod pro odvození polohy.

### Hledání osy symetrie


Důležitým doplněním informací je informace o natočení těla. Většina dat je pořizována tak, že pacient leží na zádech. Není to však pravidlem. Proto je hledána osa souměrnosti. V našem případě využíváme pro určení této osy řadu apriorních informací, které vyplývají z principu řešené úlohy. Obecněji je hledání symetrie věnována například práce Radima Tylečka [125].

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

---

Část orgánů v břišní a hrudní dutině je uložena symetricky. To však často platí jen s určitým omezením. Například pravá plíce bývá uložena výše než levá. Játra jsou uložena vpravo. Poloha srdce rovněž není souměrná dle osy těla. Pro hledání osy souměrnosti byly proto využity vysoce denzní materiály. Ty zahrnují většinu kosterního aparátu.

Nejprve je celý obraz naprahován hodnotou 430 HU. Dále je provedena projekce obrazu v ose těla. Výsledek těchto operací zobrazuje obrázek 5.4. V takto vzniklém



Obrázek 5.4: Projekce kostry

dvojměrném obraze jsou hledány parametry projekce. Zmíněné parametry popisují osu symetrie. Jedná se o souřadnice bodu  $x_s, y_s$  (pivot) a o úhel natočení osy  $\gamma_s$ , která zmíněným bodem prochází. Za tím účelem je odvozen obraz  $I_p$ , který vychází z obrazu projekce, jeho okraje jsou však rozšířeny tak, aby se pivot nalézal v jeho geometrickém středu. Dále je vytvořen osově převrácený obraz projekce. Ten je pak natočen dle  $I_m$ . Iterativně je pak ve dvou krocích nalezeno optimum kriteriální funkce:


$$E = \sum_{p_x, p_y} (I_p(p_x, p_y) - I_m(p_x, p_y))^2 \quad (5.3)$$

Kde  $p_x$  a  $p_y$  jsou souřadnice obrazových bodů posunutých projekce a jejího převráceného rotovaného obrazu.


Hledání minima kritéria je prováděno ve dvou krocích. V prvním průchodu dochází ke změně parametrů symetrie s hrubším krokem. Pivot  $(x_s, y_s)$  je posouván po 150 mm, úhel  $\gamma_s$  je měněn s krokem  $7.5^\circ$ . Ve druhém průchodu dochází k jemnějšímu upřesnění parametrů v okolí hodnot daných prvním průchodem. Krok posouvání je v tomto případě 4,5 mm a úhel je dán krokem  $1.5^\circ$ .

Na obrázku 5.6 je zobrazena osa souměrnosti kombinovaná s informací o poloze páteře.

## 5.2 Nová interaktivní segmentace kombinující informaci o jasnosti a poloze cílového objemu



**Obrázek 5.5:** Jednotlivé kroky hledání parametrů symetrie: (a) –  $I_p$  – obraz projekce posunutý tak, aby byl pivot v jeho středu, (b) – osově převrácený obraz, (c) –  $I_m$  – osově převrácený natočený obraz, (d) – kvadrát rozdílu obrazu  $I_p$  a  $I_m$




**Obrázek 5.6:** Rotace



## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

### Bránice

Nalezení hranice mezi hrudní a břišní dutinou je klíčovým úkolem pro dobrou lokalizaci uvnitř lidského těla. Postup jejího hledání využívá možnost robustního nalezení plic. Díky naplnění vzduchem jsou plice vysoce kontrastní vzhledem k ostatním tkáním. Prvním krokem algoritmu je výpočet gradientního pole. Prostřednictvím Sobelova gradientního operátoru je vyčíslena složka, která je rovnoběžná s osou těla. Z ní jsou pak pro další zpracování uvažována pouze místa s vysokými hodnotami gradientu (v naší implementaci je práh nastaven na 12). Z trojrozměrných dat je pak vytvořena dvojrozměrná reprezentace. Ta pracuje pouze s maximálními hodnotami při projekci v ose těla. Výstupy tohoto kroku jsou na obrázku 5.7 vlevo.



**Obrázek 5.7:** Lokalizace bránice. Modrá barva značí polohu nalezeného hraničního bodu blíže k nohám pacienta, červená pak značí umístění blíže k hlavě. Obrázek vlevo zobrazuje nalezené kandidáty hranice plic, pravá vizualizace ukazuje filtrovanou a interpolovanou rovinu oddělující hrudní a břišní dutinu


Předchozím krokem byly získány souřadnice bodů, které leží na rozhraní denzně odlišných tkání. Takovým místem však nemusí být nutně jen dolní okraj plic. Běžně jsou nalézány například bubliny se střevním plynem, vzduch v žaludku nebo vzduch v jícnu. Na druhou stranu je potřeba data na mnoha místech doplnit tak, aby bylo možné zkompletovat rovinu, která oddělí břišní a hrudní dutinu. Dalším krokem je tedy filtrace a interpolace dat.

Nejprve je z obrazu odstraněna výseč, která pokrývá oblast kolem srdce. Její střed je na přední straně páteře, je rozevřena na  $40^\circ$  a její osa je skloněna o  $10^\circ$  nalevo od osy souměrnosti. Většina této výseče neobsahuje kvůli vyplnění srdcem žádná použitelná data o přechodu mezi plicemi a ostatní tkání. Zpravidla se zde však objevuje vzduch v jícnu, případně bubliny střevního plynu. Tato nežádoucí informace je tedy odstraněna.

Dále je zkonstruována eliptická obálka nalezených bodů bránice. Body, které leží daleko mimo její hranice představují šum a jsou z dalšího zpracování vyloučeny. Poté jsou doplněny informace v prázdném prostoru. V bodě tohoto prostoru je nastavena

## 5.2 Nová interaktivní segmentace kombinující informaci o jasnosti a poloze cílového objemu

hodnota, která geometricky odpovídá nejbližší validní informaci. Gaussovým filtrem ( $\sigma = 7,5\text{mm}$ ) je model oddělovací roviny vyhlazen. Obrázek 5.8 zobrazuje výsled-



Obrázek 5.8: Pohled na výslednou segmentaci bránice

nou rovinu oddělující hrudní a břišní dutinu.

### Segmentace povrchu těla

Poloha orgánů v břišní dutině je do značné míry dána zejména polohou vzhledem k ose kosterního systému a bránici. Tvar jater a sleziny je však na čelní straně (ve směru ventralis) dán tvarem břišní stěny. Nalezení vnitřní hrany břišní stěny nepatří mezi snadné úlohy počítačového vidění, které by bylo možné řešit rychle a robustně. Břišní stěna však do značné míry určuje povrch těla.

Nalezení povrchu těla ve snímku z výpočetní tomografie je poměrně jednoduchou záležitostí. Zvláště pak v našem případě, kdy neklademe přílišné požadavky na jeho přesnost a postačuje nám chyba v rámci jednotek milimetrů. V naší implementaci byla hranice povrchu těla stanovována ve dvou krocích. V prvním došlo k vyhlazení dat pomocí filtrace Gausiánem, kde  $\sigma = 3$ . Druhý krok byl realizován prahováním s prahem  $-150$ .

### 5.2.2 Texturní příznaky

Pro popisování parenchymů a okolních tkání lze rovněž využít texturních popisů. Řada je jich rozvedena v části 4.1. V rámci provedených experimentů byly možnosti komplexnějších texturních popisů ověřovány. V těchto případech byl příznakový vektor tvořen následujícími příznaky. Jednotlivé příznaky byly dále kombinovány prostým spojením příznakových vektorů.

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

---

- Histogram
- Gabor-wavelet
- Gray Level Coocurance matrix
- Local Binary Patterns

Pro klasifikaci byla využita sedmice klasifikátorů, které jsou dostupné v modulu Scikit-learn [93] jazyka Python.

**Naive Bayes** , který je popsán v článku [133].

**Support Vector Machine (SVM)** o kterém se lze více dočíst v textu Smoly a Schölkopfa [110].

**Decision Trees (DT)** popsané v [98]

**Random Forest** popsané v [117]

**Linear Discriminant Analysis (LDA)** popsané v [40] a zobecněné v [99].

**Quadratic Discriminant Analysis (QDA)** lze nastudovat v [43] a v [116].

Celý obraz byl rozdělen do bloků. Nad každým blokem je prostřednictvím texturního deskriptoru určen příznakový vektor. Následuje trénování klasifikátoru. S jeho pomocí pak lze rozhodnout o tom, zda daný blok obsahuje jaterní parenchym. Ověřili jsme různé varianty příznakového vektoru. Výsledky provedených měření jsou prezentovány v části 7. Vzhledem k výpočtu po blocích jsou pro konstrukci příznakového vektoru v celém bloku stejné hodnoty pro každý obrazový bod. Je tedy zřejmé, že textury mohou sloužit pouze jako doplňující informace. Použití přesné (per pixel) texturní segmentace je dále rozvedeno v části 5.2.6.

### 5.2.3 Tvorba příznakového vektoru

Výběr příznaků je důležitým prvkem návrhu segmentačního algoritmu. V obvyklých případech je běžně užíván jednorozměrný příznakový vektor, kde je příznakem intenzita v daném místě obrazu. Pro segmentaci parenchymů je však tento přístup vhodné rozšířit. To činíme v dalších odstavcích.

Intenzita je pochopitelně v medicínských zobrazovacích metodách nezastupitelným příznakem. V případě dat z magnetické rezonance je její hodnota silně závislá na volbě parametrů snímání (T1 a T2) a v praktickém případě se tak není možné spoléhat na to, že by její absolutní hodnota byla neměnná při snímání s jiným nastavením. Proto pro MRI využíváme pouze trénování ze seedů, které nastaví uživatel pro ten který snímek.

Při využívání dat z výpočetní tomografie je situace příznivější. Rámcově je možné se spoléhat na to, že denzita určitého typu tkáně bude nabývat předpokládaných hodnot. Lze tedy předtrénovat denzitní model hledané tkáně. Model však lze významně rozšířit. V našem případě jsme vektor rozšířili o polohové informace z části 5.2.1. Dále je možné

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

---

využívat některé z metod popis oblastí z části 4.1, například wavelety 4.1.4. Příznakový vektor pro daný voxel pak tedy může obsahovat:

- intenzita voxelu
- intenzita blízkého okolí (vzniklá prostřednictvím Gaussova filtru)
- vzdálenost od roviny souměrnosti (kladná a záporná)
- vzdálenost od povrchu těla
- vzdálenost od bránice
- vzdálenost od páteře
- vzdálenost do střední axiální roviny páteře
- podobnost s předtrénovanou texturou

Využití některých texturních metrik jsou omezená. Důvodem je potřeba výpočtu nad oblastí, která je významně větší než jeden voxel. To je zpravidla řešeno rozdělením obrazu na oblasti s určitým rozměrem. Tyto oblasti mohou, ale nemusí, mít určitý překryv. Pochopitelným důsledkem těchto kroků je ztráta prostorové přesnosti, případně neúměrné navýšení výpočetních nároků.

Denzita parenchymatózních orgánů je do určité míry ovlivněna podáváním kontrastní látky před vytvořením CT snímku. Poloha těchto orgánů vzhledem k okolním tkáňovým strukturám bývá neměnná. Po patřičném natrénování lze s velkou dávkou jistoty určit malou oblast, která se s jistotou nalézá uvnitř orgánu. K jejímu určení je používána právě poloha pixelu vzhledem k významným anatomickým strukturám. V takto nalezené oblasti (viz obrázek 5.9) pak lze naměřit denzitu daného parenchymatózního orgánu pro aktuální snímek. Tuto informaci můžeme využít při tvorbě příznakového vektoru. V našem případě byl příznakový vektor rozšířen o medián z této oblasti.

### 5.2.4 Segmentace parenchymu


Před zahájením výpočtu je prováděno předzpracování vstupních dat. Ta mohou pocházet z nejrůznějších zdrojů a proto nejsou dostatečně konzistentní. Snímaná oblast někdy obsahuje pouze těsné okolí jater, jindy jsou k dispozici snímky od krku až k oblasti kyčelních kloubů. Velikost oblasti pak významným způsobem ovlivňuje výpočetní nároky. Mění se i velikost obrazového bodu. Zejména síla řezu může kolísat mezi 0,5 mm a 6 mm. Rozměr voxelu pak ovlivňuje kvalitu výsledné segmentace.

K řešení obtíží výpočetní náročností lze provádět dvě procedury: vymezení oblasti segmentace a změna velikosti voxelů. V části 5.2.5 pak navrhujeme i alternativní přístup, který výpočet urychlí.

Vlastní segmentace probíhá kombinací několika metod. Použit je natrénovaný model orgánu, jehož příznakový vektor může zahrnovat informaci o poloze jednotlivých voxelů vzhledem k významným okolním tkáním a také informaci o jejich denzitě, případně

## 5.2 Nová interaktivní segmentace kombinující informaci o jasnosti a poloze cílového objemu

---



**Obrázek 5.9:** Odhad polohy jater na základě polohy významných anatomických struktur. Jednotlivé křivky vyznačují místa se stejnou věrohodností.

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

pracovat s texturou. Na základě krátké uživatelské interaktivity jsou určena místa (seedy), která s jistotou náleží segmentovanému parenchymu, ale i taková, která s jistotou náleží pozadí. Spojením dat od uživatele s předtrénovaným modelem je nashromážděna informace, která je využita pro segmentaci prostřednictvím metody Graph-Cut.


V některých případech je výhodné rozložit segmentaci na dva kroky. V prvním kroku je na základě natrénovaného modelu určena poloha parenchymu a v jejím středu je vytvořen návrh seedů pro uživatele. Tento krok lze provádět automaticky a nezatěžovat obsluhu. V druhém kroku je pak prováděna uživatelská interakce, která může mít parametry nastavené tak, aby byl výpočet dostatečně rychlý.

### 5.2.5 Vícemřítková segmentace pomocí Graph-Cut

Data z trojrozměrných lékařských metod jsou charakteristická svým objemem. I přes velkou efektivitu algoritmu užívaného pro výpočet řezu grafu v Graph-Cut segmentaci, je doba výpočtu nezanedbatelná. Za účelem zefektivnění výpočtu byla navržena vícemřítková segmentace pomocí metody Graph-Cut. Ta využívá té skutečnosti, že cílový objem je dosti kompaktní a hranice segmentace zaujímá nevelkou oblast celkového objemu vstupních dat.

Na základě podobného východiska byla navržena segmentační metoda pro mikroskopii světlého pole (bright-field), která byla popsána v článku [65] a využívá práci s pravoúhlými výřezy z hrubě segmentovaných dat. Metoda je podrobněji popsána v části 4.2.5.

Cílem našeho procesu je vytvoření výpočetní sítě, která je jemná v okolí okraje segmentace a hrubá všude jinde 5.10.



Obrázek 5.10: Schema různě velikých voxelů


Prvním krokem procesu je provedení hrubé segmentace na převzorkovaných datech. Je zvolena velikost bloku, která udává kolikrát je sníženo rozlišení převzorkovaných

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

dat. Obdobným způsobem dochází k převzorkování seedů. V tomto případě je použito interpolace dle nejbližšího souseda. V místech blízko hranice se mohou objevit sporné případy, kdy mohou být uvnitř bloku pixely reprezentující seedy popředí i pozadí. V naší implementaci jsme ponechali rozhodování na pravidlu nejbližšího souseda. V zásadě by však mohlo být lepším řešením seed v nerozhodném voxelu zcela odstranit. Následně je provedena segmentace běžným způsobem. Vzhledem k nízkému rozlišení obrazových dat probíhá tento proces velmi rychle.

Následujícím krokem je určení oblastí, které budou určeny k výpočtu s jemným rozlišením. Jedná se o místa podél hranice hrubé segmentace z předchozího kroku. Jedním z parametrů naší metody je pak šíře tohoto pásma. Tím mohou být zahrnuty bloky, které jsou blízko hranice, avšak přímo se jí nedotýkají. Tento parametr je pak volen s přihlédnutím k předpokládané tvarové bohatosti segmentovaného objektu.

Konstrukce grafu pak vychází z předchozích kroků.



Obrázek 5.11: Konstrukce hran grafu typu N-links

Druhou operací předzpracování je převzorkování, které bude rozebráno v dalším textu. Tím je, kromě snížení paměťových nároků, zajištěna i stejná velikost voxelů pro všechna data. To usnadňuje další zpracování.

Základem procesu je segmentace pomocí Graph-Cut algoritmu. Uživatel pomocí myši zvolí několik voxelů, které reprezentují sledovaný objekt a pozadí. Modely intenzity (denzity) těchto dvou objektů jsou tvořeny několika způsoby. Jsou modelovány pomocí tříšložkové gaussovské směsi z označených voxelů pomocí EM algoritmu [29]. Takto vytvořený model je užit pro návrh vah v segmentačním procesu. Dle [16] a [15] je sestaven graf a nastaveny příslušné váhy. T-linky odrážejí oblastní vlastnosti obrazu

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

---

(intenzitu) a jsou dány následujícími rovnicemi:

$$R_p(\text{obj}) = \ln(\Pr(I_p|O)) \quad (5.4)$$

$$R_p(\text{bkg}) = \ln(\Pr(I_p|B)) \quad (5.5)$$

$R_p(\text{obj})$  představuje váhu mezi uzlem, který odpovídá pixelu a uzlem, jež reprezentuje objekt. Tato váha je dána modelem objektu  $R_p(\text{obj})$ . Druhá rovnice je obdobu téhož pro pozadí.

Dále jsou určeny váhy mezi sousedícími voxely. Běžně je využíváno konstantní nastavení vah, které umožňuje penalizovat velký povrch nasegmentovaného objektu. Experimentálně je naimplemetována i forma využívající hranový přístup:

$$B_{p,q} \propto \exp\left(-\frac{(I_p - I_q)^2}{2\sigma^2}\right) \cdot \frac{1}{\text{dist}(p,q)} \quad (5.6)$$

V této rovnici  $I_p$  a  $I_q$  představují intenzity obrazu,  $\sigma$  je odhad šumu a  $\text{dist}(p,q)$  je vzdálenost mezi uzly  $p$  a  $q$ .

Od algoritmu, který je popsán v článku [65] se zde navržený přístup liší tím, že pracuje nadále s celým objemem dat. Navíc je schopen zjednodušovat výpočet i uvnitř pravoúhlého obalu segmentované oblasti.

V části 7.4 jsou představeny výsledky experimentů s víceměřtkovou segmentací.

### 5.2.6 Dvoustranná texturní segmentační kombinující Gabor-wavelet a Graph-Cut

S cílem zlepšení kvality segmentace na rozhraní dvou textur jsme navrhli novou segmentační metodu. Výstupem metody je segmentace obrazu, který obsahuje dvě známé textury, objekt a pozadí. Vstupem je tento obraz a vzorek každé z textur (případně model). Základem metody je kombinace texturní analýzy pomocí Gaborových filtrů a segmentační metody Graph-Cut.

Model textury jednotlivých objektů byl vytvořen s využitím Gaborových filtrů, které byly popsány v části 4.1.4. Byla vytvořena banka filtrů se třemi frekvencemi a čtyřmi různými natočeními. Celkem tedy 12 filtrů. Pro zvýšení přesnosti na rozhraní byl zvolen přístup s dvoustrannou texturní analýzou, byl tedy vytvořen model pro levé, pravé, horní a dolní okolí zkoumaného pixelu. Ten je tvořen třísložkovou gaussovskou směsí.

Segmentace je realizována prostřednictvím metody Graph-Cut. Váhy T-linek (obrázek 5.12) mezi objekty jsou voleny průměrováním věrohodností ve všech směrech ( $\bar{U}^O$ ):


$$\bar{U}^O = \frac{1}{N} \sum_{n=1}^N U_n^O(\mathbf{x}_p|\theta_n) \quad (5.7)$$

$$R_p^O = -\ln(\bar{U}^O) \quad (5.8)$$

Kde  $R_p^O$  je ohodnocení hrany mezi pixelem  $p$  a terminálem, který odpovídá objektu  $O$ ,  $N$  označuje počet polorovin dvoustranné texturní analýzy a  $U_n^O(\mathbf{x}_p|\theta_n)$  je věrohodnost zařazení pixelu  $p$  do třídy objektu pro  $n$ -tou polorovinu.



## 5.2 Nová interaktivní segmentace kombinující informaci o jasnosti a poloze cílového objemu



**Obrázek 5.12:** Váhy typu T-link pro popředí ( $R_p^O$ ) a pozadí ( $R_p^B$ )

První přístup, který byl využit jako srovnávací segmentace je velmi prostý. Jedná se o segmentaci prostřednictvím věrohodnosti texturního modelu, který je tvořen gaussovskou směsí. Dále je tento přístup označován jako „Segmentace Gaborovými filtry“.

Metoda kterou jsme navrhli jako rozšíření zmíněného přístupu je kombinace Gabor-waveletu a Graph-Cutu (Gabor Filter Graph-Cut segmentation (GFGC)), která pro výpočet sousedních vah (N-linek) využívá volbu vah dle [16] a [15].

$$B_p = \exp\left(-\frac{Q_n^2}{2\sigma^2}\right) \quad (5.9)$$

Hodnota  $Q_p$  představuje zvolený pixel z obrazu  $Q$  a modeluje míru důvěry v to, že daný pixel náleží popředí.

$$Q = \log\left(\frac{\bar{U}^O \cdot \bar{U}_{n'}^B}{\bar{U}_{n'}^O \cdot \bar{U}_n^B}\right) \quad (5.10)$$

$\sigma$  v rovnici 5.9 zpravidla představuje rozptyl intenzit obrazu. Zde je  $\sigma$  volena jako rozptyl z  $Q_n$  je voleno jako rozdíl sousedních intenzit v obrazu  $Q$ . Vizualizaci vah typu N-link znázorňuje obrázek 5.13.


Pokročilejší přístup k výpočtu lokálních změn využívá naplno dvoustranné analýzy. Dále jej označujeme jako „Two-sided Gabor Filter Graph-Cut segmentation (TSG-FGC)“. Podstatou je porovnání věrohodností v protilehlých polorovinách. To je realizováno prostřednictvím vynulování jedné poloviny Gabor-waveletu. To je ukázáno v rovnici 5.11. V ní  $n$  představuje směr poloroviny a  $n'$  je směr opačné poloroviny.  $U_n^O$  a  $U_n^B$  jsou věrohodnosti objektu a pozadí pro směr  $n$ .  $U_{n'}^O$  a  $U_{n'}^B$  znamenají věrohodnosti pro opačný směr.

$$Q_n = \log\left(\frac{U_n^O \cdot U_{n'}^B}{U_{n'}^O \cdot U_n^B}\right) \quad (5.11)$$

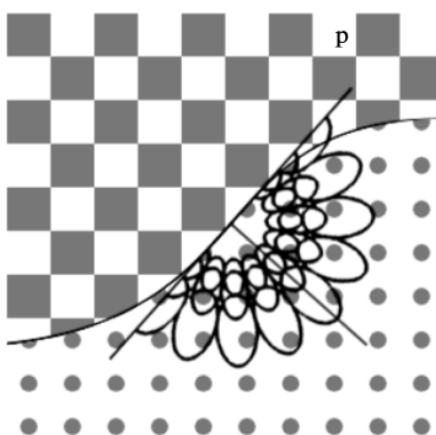
Obrázek 5.14 dokumentuje působnost poloviny Gabor-waveletu. Hodnoty N-linků jsou

## 5.2 Nová interaktivní segmentace kombinující informaci o jasnosti a poloze cílového objemu

---



Obrázek 5.13: Váhy typu N-link ( $B_p$ ) pro horizontální a vertikální směr



Obrázek 5.14: Ukázka popisu prostřednictvím dvoustranného filtru

## 5.2 Nová interaktivní segmentace kombinující informaci o jasu a poloze cílového objemu

---

vyjádřeny následující rovnicí, která vychází z výpočtu vah v článku [14].

$$B_{np} = \exp\left(-\frac{Q_n^2}{2\sigma^2}\right) \quad (5.12)$$

Zde tato hodnota  $\sigma$  odhadnuta jako rozptyl z  $Q_n$ .

Experimenty ověřující segmentační metodu na syntetických datech jsou popsány v části 7.5. Metodu i s experimentem jsme publikovali v článku [60].

### 5.2.7 Přesná segmentace na okrajích

Jedním ze způsobů snížení výpočetních nároků segmentačních metod je snížení objemu dat prostřednictvím převzorkování a vymezením oblasti zájmu. Kvalita segmentace blízko jejímu okraji tímto procesem poněkud trpí. Nepřesnosti na okrajích rovněž vycházejí z principu snímání dat. Výsledný jas obrazového bodu (například CT) je integrací míry absorpce rentgenového záření v určitém objemu. U magnetické rezonance je situace obdobná. Na přechodu dvou tkání je tak výsledný jas směsí odezev těchto dvou tkání. Voxely na okraji jaterního parenchymu, tak mohou mít denzitu, která zcela neodpovídá denzitě uvnitř tkáně. Pro strojovou segmentaci může mít tento jev neblahý vliv na přesnost segmentace.

Při srovnáních výsledků manuální segmentace a strojové segmentace pomocí Graph-Cut trpí strojová metoda mírnou podsegmentací. Výsledný objem manuálních segmentací je obvykle o něco větší. Navrhujeme proto zavedení dodatečného zpracování, které by výše zmíněné nedostatky kompenzovalo.

### Vyhlazování

V důsledku převzorkování vstupních dat na jednotné (a zpravidla hrubší) rozlišení trpí výsledná segmentace artefakty na okrajích, které jsou produkty hrubších voxelů. Tyto artefakty pochopitelně neblaze přispívají ke snižování skóre většiny používaných hodnotících metrik. Jako jednoduché řešení jsme navrhli proceduru vyhlazování povrchu. Výstupní segmentace z Graph-Cut je filtrována Gaussovským filtrem o definovaném rozptylu.

### Navýšení objemu

Zvětšení objemu rovnoměrně po celém povrchu využívá apriorní informaci o nedokonalosti segmentačních metod. Námi navržený model reprezentace dat využívá trojrozměrné pole, které odráží jednotlivé voxely. Nelze zde tedy pracovat se subpixelovou přesností. Základní návrh navýšení objemu využívá binární morfologické operace a okraj segmentace je vždy zvětšen o slupku o šíři jeden voxel. To však zapříčiňuje navyšování objemu jen po určitých kvantech.

Byla navržena metoda, která umožňuje zvětšovat objem v jemnějších krocích. Na binární segmentaci je aplikován Gaussovský filtr. Data jsou tak na okrajích rozostřena.

Dále je sestaven kumulativní histogram. Z něj lze odečíst prahovací hodnotu, která zajistí, že velikost výsledného objemu se velmi blízký vstupnímu požadavku.

Slabinou tohoto přístupu je chybějící kontrola nad místem nárůstu. Ten se bude dít zejména v komplikovaných záhybech jaterního parenchymu. Dochází ke zlepšení hodnot kritéria, které hodnotí poměrný rozdíl objemů (Volume Differece (VD)). Patrně však může docházet ke zhoršování ostatních metrik.

### Snakes

Vyhlazení objemu a jeho navýšení bez uvážení lokálního kontextu dat má pochopitelné limity. Proto jsme navrhli posprocessing, který respektuje jasové hodnoty původních dat. Základem je algoritmus Active Contour Model (ACM)(známý rovněž jako „snakes“), který je popsán v části 4.2.4. Použita je implementace popsaná v [81], [2] a [77], kterou jsem rozšířil o možnost doplnění dvou typů klíčových bodů. S jejich pomocí je možno označit části, které budou napevno součástí výstupní segmentace, respektive částí, které součástí výstupní segmentace být nesmějí. Tato funkcionalita se překrývá s vlastnostmi seedů charakteristických pro metodu Graph-Cut. Ty jsou proto využity i v tomto kroku zpracování.


## 5.3 Vyhodnocení

Kapitola pojednává o modelování geometrie parenchymatózních orgánů. Cílem této části je popis tvaru a polohy parenchymu. Extrakce této informace ze snímků z trojrozměrných zobrazovacích metod je prováděna prostřednictvím segmentace. Její výstup je pak použit pro tvorbu povrchového modelu, který je klíčovou součástí při modelování prokrvení. Obrázek 5.15 zobrazuje vizualizaci tvarového modelu jaterního parenchymu.

Navržena byla metoda pro určení polohy v těle člověka, která může být zobecněna na použití pro experimentální zvíře. Metoda, která je popsána v části 5.2.1, využívá významné anatomické struktury, které jsou v CT snímcích dobře patrné. Jedná se o osu kosterního systému, plíce a povrch těla.

Pro segmentaci jsou pak společně s informacemi o poloze jsou využívány informace o denzitě, případně i o textuře. Byla navržena metoda dvoustranné texturní analýzy, která kombinuje Gabor-wavelet a Graph-Cut. Metoda byla publikována v článku [1]. Metoda byla ověřena vzorcích 300 textur a byla porovnána s dalšími segmentačními metodami. Experimenty popisující možnosti příznakových vektorů vycházejících z texturních popisů, které jsou použity v na trojrozměrná data parenchymů, byly publikovány v článku [59]. Podrobnosti jsou v části 7.5.

S přihlédnutím ke klinickým zkušenostem byla navržena interaktivní segmentační metoda. V porovnání s běžnými klinickými metodami zajišťuje velkou kontrolu uživatele nad výsledkem a značně snižuje jeho mentální zátěž. Experimenty, které ověřují kvalitu segmentace a volbu parametrů, jsou popsány v části 7.2.



Obrázek 5.15: Ukázka tvarového model parenchymu jater

## 6

# Geometrický model cévního řečiště

Popis mechaniky proudění krve ve vaskulatuře parenchymů je klíčem k pochopení funkce těchto orgánů. Proto je jejímu studiu věnována řada prací na nejrůznějších pracovištích. Nás zajímá zejména kvůli návaznosti na probíhající výzkum v oblasti regenerace jater. Rozmanitost průřezů a typů cévního řečiště představuje výzvu pro jakékoliv zpracování. Běžné bývá vysoce manuální hodnocení, které představuje mimořádnou zátěž pro obsluhu.

Naším cílem v této kapitole je tedy prostřednictvím metod počítačového vidění navrhnout postupy, které povedou k vytvoření geometrického modelu zvoleného cévního řečiště. Tento model pak bude umožňovat provádění komplexních hodnocení na mikroskopické i makroskopické úrovni. Po zasazení do širšího kontextu s tvarovým modelem parenchymů z kapitoly 5 pak bude umožňovat provádění výpočtů proudění krve v těchto orgánech. V kontextu výzkumu jater je perfuze klíčovým faktorem ovlivňujícím regeneraci tohoto orgánu.

### 6.1 Model cévního stromu


V naší práci pro modelování cévních stromů na makro a mikro úrovni navazujeme na předchozí práci kolegů [120] a [45]. Na základě jejich připomínek jsme vytvořili s přispěním studentů (Jiřího Kuneše, Pavla Volkovinského a dalších) aplikaci, jejíž základní metody jsou popsány v článku [58]. Námi vytvořená aplikace pracuje s běžnými soubory ve formátu DICOM (Digital Imaging and Communications in Medicine), které jsou využívány v medicínské praxi. Alternativou je pak jakýkoliv formát podporovaný knihovnou SimpleITK ([76]).

Výchozím bodem statistického zpracování mikrostruktury jaterního parenchymu jsou vstupní data. Nahraná data je často nutné před hlavním zpracováním upravit. Nejdříve jsou tedy data oříznuta pouze na oblast, kterou chceme zpracovávat, dále z nich mohou být odstraněny menší podoblasti, které potřebujeme vyloučit z výsledných dat. Nakonec je na odstranění šumu ve vstupních datech použit mediánový filtr, který byl vybrán z důvodu potřeby zachování ohrazení jednotlivých cév.

Po předzpracování následuje segmentace, jejíž práh se dá nastavit manuálně nebo

grafickým vybráním několika bodů v objemu volitelné cévy. Ze získaných nasegmentovaných dat jsou následně odstraněny díry a ostatní chyby segmentace pomocí nastavitelného počtu iterací dilatace a eroze.

Z takto nasegmentovaných volumetrických dat je pomocí knihovny `thinning3D` ([83]) vytvořen skeleton. Jeden řez trojrozměrným obrazem s označením skeletonu znázorňuje obrázek 6.1. Knihovnu jsem vytvořil pro potřeby využívání ztenčovacího algoritmu popsaného v [51].




**Obrázek 6.1:** Řez segmentovanými daty se znázorněním skeletonu

Následně jsou ve skeletonu pomocí konvoluce nalezeny uzlové a koncové body, které rozlišují začátek a konec každé cévy. Skeleton je reprezentován polem, kde je v místě skeletonu hodnota jedna a mimo skeleton jsou nuly. Vyhodnocován je pak součet v okolí  $3 \times 3 \times 3$ . V místě průběžné části je tento součet roven třem, v místě uzlu je větší. Kde je součet menší, jedná se o koncový bod skeletonu. Výpočet je realizován prostřednictvím konvoluce s malou maskou.

V takto vzniklé kostře se objevuje celá řada artefaktů, které nijak nesouvisí s tvarem objektu, ale jsou důsledkem obecné numerické nestability skeletonizačních algoritmů. Situaci znázorňuje obrázek 6.2. Jedná se o artefakty dvojího druhu.

- Drobné výběžky z těla cév (situace B)



**Obrázek 6.2:** Ukázka komplikovaných situací při tvorbě skeletonu

- Příliš komplikované větvení (situace C)

Z toho důvodu jsme navrhli vyhlazovací fázi, která tyto nedostatky zmírňuje. Jedná se o umělé zvětšení poloměru uzlů. Tím dochází ke spojení blízkých uzlů v jeden a zároveň jsou s uzlem spojeny krátké větve. Druhým krokem je zpracování na úrovni grafu, které odstraňuje cévy vybrané s ohledem na jejich poloměr a délku.




**Obrázek 6.3:** Ukázka modelu cévního řečiště. Vlevo jednoduchá reprezentace, vpravo reprezentace s modelovanými spoji

Z takto upraveného skeletonu cévního stromu lze vytvořit grafovou reprezentaci spojení jednotlivých segmentů cév. Každá část cévy mezi dvěma větvenými je reprezentována jako hrana grafu. Lze pro ni odhadnout základní parametry - délku a průsvit.



Takováto reprezentace je nazývána 1D model. Lze přitom vycházet z určitých anatomicky podmíněných předpokladů. Céva nemění mezi větvenými výrazně svůj průřez. Při lokálním zmenšení by docházelo k namáhání stěny cévy a běžnými fyziologickými procesy by došlo k opětovnému rozšíření. Z obdobných důvodů lze předpokládat, že průřez cév je přibližně kruhový.

### 6.1.1 Reprezentace cévních struktur



**Obrázek 6.4:** Vizualizace cévní mikrostruktury pomocí LAR

Podstatným důležitým prvkem pro zkoumání cévních struktur je jejich reprezentace v paměti stroje. Vzhledem k velkým rozměrům vstupních dat se jedná o netriviální úlohu. Ve spolupráci s kolegou Albertem Paoluzzim z Roma Tre Univerzity jsme vytvořili vizualizaci cévní mikrostruktur lineární algebraické reprezentace (Linear Algebraic Representation (LAR)), která je na tomto pracovišti vyvíjena. Jedná se o neobvyklou techniku reprezentace objektů, která využívá Combinational Cellular Complexes [8] jako svou hlavní doménu. Díky tomuto přístupu lze například základní morfologické operace počítat maticovým součinem reprezentační matice s příslušným operátorem.

Postup vytváření vizualizace jaterní mikrovaskulatury je popsán ve společném článku [91]. Ukázkou výsledků je možné vidět na obrázku 6.4. Ta znázorňuje i dokonalější model větvení cév.

## 6.2 Modelování perfuze jater

Modelování proudění krve lidskými játry je komplikovaná úloha z důvodu široké škály měřítek, na kterých musí daný model popisovat chování kapaliny v odlišných podmínkách. Míra našeho porozumění detailního chování složitých procesů je značně omezená. Charlotte Debbaut ve své práci [28] a [27] navrhla model popisující tlaky v cévách na různých úrovních cévního stromu na základě statistického popisu geometrie. Dlouhodobým cílem týmu vědců ze Západočeské univerzity a Lékařské fakulty Univerzity Karlovy v Plzni je prohloubení poznatků o jaterní perfuzi na základě numerického modelování toku kapaliny v geometrickém modelu jaterního parenchymu na všech úrovních.

Představu o poměrech v cílovém modelu lze získat porovnáním rozměrů cévy, která přivádí většinu krve do jater s cévami v jaterním lalůčku. Portální žíla má průměr  $D = 1,3\text{cm}$ . Postupně se větví na cévy s menším průměrem. Počtem větvení, které každou cévu dělí od vstupu do jater, lze určit míru vnoření. Alternativně lze počítat počet větvení od jaterního lalůčku. Tyto údaje pak korespondují s průměrem cévy. Lidská krvinka má průměr  $7.2\mu\text{m}$  a tloušťku asi  $2\mu\text{m}$  (viz [20, 5]). Nejjemnější mikrocévy jaterního lobulu mají průměr  $d = 10\mu\text{m}$ . Průměry cév, které zajišťují průtok krve játry tak plynule prochází měřítkem  $d/D \doteq 0,001$ .

Kolegové z katedry mechaniky Fakulty Aplikovaných věd Západočeské univerzity navrhli model, který postihuje většinu podstatných aspektů jaterní perfuze. Model je ukázán na obrázku 6.5. Makroskopická část modelu vychází z dat, která lze získat z běžných klinických vyšetření. Na základě CT snímku je využit mnou navržený geometrický model cévního stromu. Mikroskopická část využívá víceměřítkové modelování proudění kapaliny, které vychází ze statisticky měřených dat. Data jsou extrahována z mikro-CT snímků korozivních preparátů jater prasete.

### 6.2.1 Modelování proudění v makroskopickém měřítku

Tok v cévách většího průměru (než 2 mm) je modelován jednoduchým 1D modelem, který vychází z Bernoulliho rovnice:


$$A_0 w_0 = \sum_k^n A_k w_k \quad (6.1)$$

$$\frac{1}{2} \rho w_0^2 + p_0 = \frac{1}{2} \rho w_k^2 + p_k + e_k^{\text{loss}}, \quad k = 1, 2, \dots, n \quad (6.2)$$

kde  $\rho$  představuje hustotu kapaliny,  $A_k$  je průřez větvi cévního stromu a  $n$  je počet koncových bodů cévního stromu (grafu).  $w_0$  je vstupní rychlost a  $p_0$  je vstupní tlak. Parametry  $w_k$  a  $p_k$  pak představují rychlost a tlak v koncových bodech.  $e_k^{\text{loss}}$  představuje ztráty třením v nepružných trubicích, kterými je tento model tvořen.

$$e_k^{\text{loss}} = \frac{1}{2} \rho w_k^2 \frac{L}{D} \frac{64}{\text{Re}_k} \quad (6.3)$$

Parametr  $L$  a  $D$  představují délku a průměr větve stromu a  $\text{Re}_k$  je Reynoldsovo číslo.



Obrázek 6.5: Schéma vícemřítkového numerického modelu perfuze jaterního parenchymu

Výhodou tohoto popisu jsou nízké výpočetní nároky v porovnání s plným 3D popisem.

### 6.2.2 Mikroskopický model proudění

Model v mikroměřítku je tvořen kompartmenty  $C_j$ , které jsou rozděleny právě podle úrovně vnoření, případně dle průřezů cév. Jsou řetězeny tak, aby reprezentovaly přívod krve k lalůčce portálními řečištěm  $P$  a jeho drenáž prostřednictvím jaterních žil  $H$ . Struktura modelu dále respektuje anatomii cévního systému rozdělením do segmentů.

Využit je idealizovaný jaterní perfuze kombinující trojici koexistujících kompartmentů. První ( $C_1$ ) je připojen k 1D makroskopickému modelu portální žíly a slouží jako vstup kapaliny do Darcyho modelu. Střední kompartment reprezentuje filtrační systém jaterního lobulu. Poslední kompartment ( $C_3$ ) je připojen k systému, který reprezentuje jaterní žíly ( $C_{k+1}, C_{k+2}, C_{k+3}$ ). Ty zajišťují odtok krve z jater.


Vícekompartmentový Darcyho systém je popsán takto:

$$\nabla w^i + \sum_j G_j^i (p^i - p^j) = f^i \quad (6.4)$$

$$w^i = -K^i \nabla p^i, i = 1 \dots N \quad (6.5)$$


kde  $K^i$  je lokální permeabilita a  $G_k^i$  je perfuzní koeficient mezi  $k$ -tým a  $i$ -tým kompartmentem.  $G_j^i (p^i - p^j)$  reprezentuje množství kapaliny, která přechází mezi dvěma segmenty.

Určení tenzoru permeability  $K_i$  je popsáno v práci [52] a vychází z teoretických prací [129], [54] a [55]. Vstupní informací jsou pak geometrické vlastnosti mikrostruktury, které popisují jednotlivé segmenty. Ilustruje je obrázek 6.6. Jedná se o délku  $l$ , přírůstky  $\Delta X_1$  a  $\Delta X_2$  a průměr segmentu  $l$ .



Obrázek 6.6: Ilustrace cévních segmentů, převzato z [129]

Vizualizaci vypočítaných rychlostí ve filtračním systému je možné nalézt na obrázku 6.7. Kromě perfuze umožňuje takto navržený model odhadovat i šíření kontrastní látky v jaterním parenchymu.



**Obrázek 6.7:** Perfuzní rychlosti ve filtračním systému, viz [8]

Podrobnosti o obecném návrhu víceměřítkového hierarchického modelu lze najít v [100] a [64]. Využití cévního stromu extrahovaného prostřednictvím mnou navržených metod je popsáno v článku [8]. Dokonalé určení permeabilit stále představuje výzvu pro budoucí výzkum. Řada kroků již byla v tomto ohledu učiněna. Jedním z nich je kvantitativní popis jaterní mikrostruktury představený v části 6.5.3. Tento postup byl použit a publikován v našem článku [4].

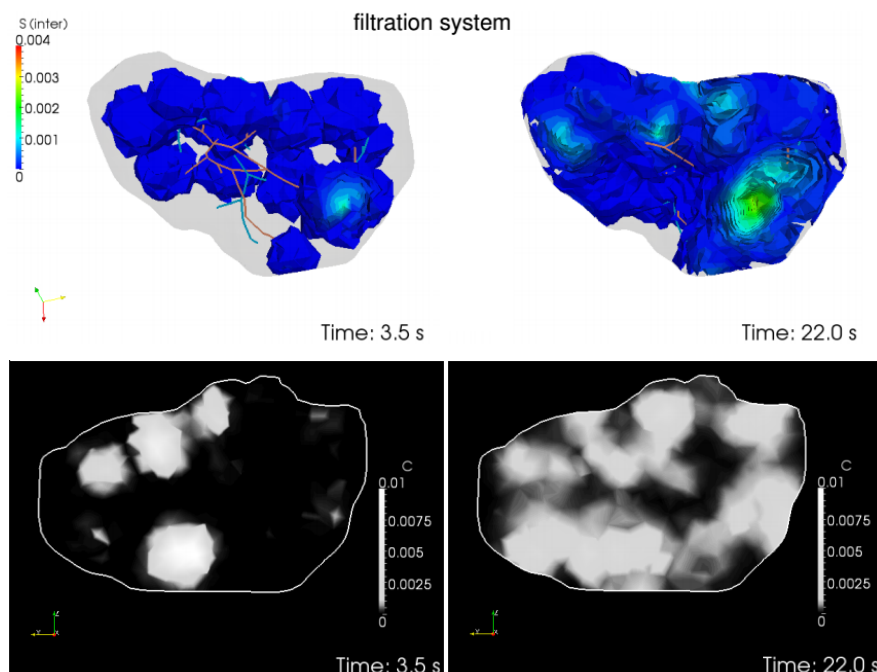
### 6.2.3 Geometrický model pro modelování prokrvení

Modelování prokrvení orgánu je možné realizovat různými matematickými přístupy, které jsou popsány v části 6.2. Tato úloha si žádá jako vstup tvarový model parenchymu, který byl navržen v předchozí kapitole. Ten poskytuje rámec pro hlavní výpočty. Předpokládá se, že stěna parenchymu je neprostupná.

Dalším nezbytným vstupem je model cévního systému. Ten je například v játrech reprezentován dvěma druhy cév. Jeden z jich přivádí krev do orgánu, druhý ji odvádí pryč. Například v případě jater je přívodní cévou portální žíla a jaterní tepna. Odvod krve je zajištěn jaterními žilami.

## 6.3 Analýza mikrovaskulatury

Předchozí text práce předkládá odpovědi na základní otázky týkající se geometrie velkých cév. Pro dobré porozumění funkci jaterního lalůčku, který představuje základní stavební jednotku celého orgánu, je však nezbytný detailnější pohled. Ten nám v budoucnosti umožní nahlédnout například pod pokličku jevů, které souvisejí s odumíráním



**Obrázek 6.8:** Časový vývoj distribuce kontrastní látky. Nahoře je vizualizace filtračního systému, dole je zobrazena koncentrace v transverzálním řezu

tkáně jaterních buněk v důsledku nerovnováhy mezi tvorbou a odbouráváním mimobuněčné hmoty.

Studiu mikrostruktury je věnována celá řada prací. V článku [44] je ke studiu struktury jaterního lalůčku s nezměněnou anatomíí využívána kombinace korozivního preparátu a elektronové mikroskopie. Pracoviště z Ghentu publikovalo práce [28] a [27] v nichž se autorka věnuje vytváření modelu jater pomocí tomografického vyšetření mikrokorozivního preparátu. Data vycházejí z malého množství dostupných jater (původně jediná játra), která byla zpracovávána dlouhé měsíce s využitím velkého množství ruční práce. Náš přístup má s tím jejím společné znaky, avšak naším cílem je zpracovat násobně větší množství dat (řádově 10 preparátů za rok). Zároveň je naší snahou vytvořit kvalitativně jiný druh modelu, který více vychází z vnitřní podstaty zkoumaného jevu (tedy proudění kapaliny).

Trojrozměrná data z CT v našem výzkumu jsou vyžadována pro určení mechanických parametrů pro potřeby modelování proudění krve. Průtok kapaliny pískem bude nepochybně odlišný od průtoku jiným materiálem (například houbou). Tento jev se snažíme popsat matematicky pomocí perfuzních parametrů. Jednoduše (a tím i nepřesně) to lze vyjádřit permeabilitou, která reprezentuje souhrn perfuzních parametrů. Výzkum, který navazuje na tuto práci, se snaží nalézt souvislost mezi těmito parametry a popisy struktur, které vycházejí z moderní stereologie.

### 6.4 Příprava vzorků pro vytvoření modelu cévní mikrostruktury

Výchozím bodem pro naši další práci jsou trojrozměrná data zachycující cévní mikrostrukturu. Pomocí mikro-CT přístroje je vytvořen snímek malé části korozivního preparátu jater prasete. Metodika pro přípravu dat je podrobně popsána v disertační práci Lady Eberlové [34]. Následující popis ze zmíněného textu čerpá a přibližuje základy celého postupu.



**Obrázek 6.9:** Příprava korozivního preparátu, pravý obrázek převzat z [34]

Malé prase o hmotnosti 25 kg bylo za součinnosti chirurgického týmu a anesteziologa uvedeno do celkové anestézie. Přístup do břišní dutiny byl zjednáán z horní střední laparotomie rozšířená pod pupek. Po uvolnění jater ze závěsů a zpřístupnění cava inferior nad játry dochází k postupné preparaci vena portae a arteria hepatica communis. V dalším kroku je nastřížena bránice a dochází k zasvorkování vena cava inferior. Po provedení venotomie této cévy jsou zavedeny katetry zafixované ligaturou a je zahájen průplach parenchymu. Protnutím ligamenta hepatoduodenale je zajištěna drenáž proplachového roztoku. Během dvou minut dochází k vyblednutí jater. Průplach je ukončen až po vytékání čiré tekutiny.

Játra vyjmutá z břišní dutiny jsou nadále ponechána pod vodní hladinou z důvodu omezení rizika vzduchové embolie. Do portální žíly je pak injektována směs pryskyřice Biodur E20 a žluté barvicí pasty (viz obrázek 6.9). Napuštěný preparát tuhne asi 40 minut a je ponechán ve vodě do dalšího dne. Pomocí hydroxidu draselného (KOH) je pak prováděno odleptání měkkých tkání.

V dalším kroku je pak nutné zvolit část vhodnou pro další zkoumání. Zvolená část je pak oddělena od zbytku. V našem případě byl použit cutter Proxxon Micro Band Saw 240-E. Výpočetní tomografie pak byla zprostředkována přístrojem Xradia XCT 400 s různým rozlišením  $4,5\mu m$ ,  $9,5\mu m$ ,  $17\mu m$  a  $53\mu m$ . Ukázka naměřených dat je k vidění na obrázku 6.12.

Netriviálním úkolem je srovnání makroskopických CT snímků s mikro-CT snímkem.

## 6.4 Příprava vzorků pro vytvoření modelu cévní mikrostruktury




Obrázek 6.10: Korozivní preparát jaterních cév prasete



Obrázek 6.11: Oddělení vzorku od korozivního preparátu celých jater. Vlevo pila Proxxon Micro Band Saw 240-E, vpravo pak oddělený vzorek. Viz [34]



## 6.5 Poloautomatická kvantitativní analýza tkáňových vzorků



**Obrázek 6.12:** Vzorek Micro CT řezů korozivního preparátu jaterních cév s rozlišením  $0.004682 \times 0.004682 \times 0.004682$  [mm] a velikostí  $992 \times 1013$


Po oddělení snímaného vzorku a jeho další přípravě pro vložení do mikro-CT přístroje se rozpadá informace o orientaci odřezku k zbytku korozivního preparátu. Při pozvolném snižování rozlišení lze tento problém vyřešit. Na obrázku 6.13 je vidět porovnání snímků stejné oblasti z různých přístrojů.

## 6.5 Poloautomatická kvantitativní analýza tkáňových vzorků

Statistické zpracování objemových tkáňových vzorků pomocí kvantitativních metod vychází z vývoje oboru stereologie. Ta vychází z geometrie a zabývá se vlastnostmi a hodnocením trojrozměrných struktur rozmanitého původu prostřednictvím pozorování orientovaných dvojrozměrných řezů daným vzorkem. Předmětem zkoumání histologie je zpravidla jen několik řezů, které pocházejí z mikroskopu. Data z trojrozměrných metod nejsou až tak obvyklá. Používané metody jsou tedy navrženy tak, aby na základě několika málo řezů byly schopny sestavit určitou statistiku o daném vzorku.

Stereologické metody spočívají v rozvíjení Cavalieriho principu, který popisuje vztah mezi vlastnostmi trojrozměrného tělesa a sérií ekvidistantních řezů tímto tělesem. Podrobnosti lze dohledat v [7]. Tyto metody tak tkví v postupném procházení vstupních dat z micro-CT řez po řezu, cévu po cévě. Při určení jednotlivých statistických metrik, které popisují objem, plochu, délku či počet, je využíváno manuální práce pozorovatele.

## 6.5 Poloautomatická kvantitativní analýza tkáňových vzorků



**Obrázek 6.13:** Porovnání snímků z běžné výpočetní tomografie a mikro-CT. Vlevo snímky z přístroje Siemens Somatom Sensation 64, vpravo snímky z Xradia XCT 400

## 6.5 Poloautomatická kvantitativní analýza tkáňových vzorků

Ten určuje vzájemné vztahy sledovaných dat a geometrických testovacích sond rozličného tvaru i dimenze. Obvykle tato činnost obnáší postupnou analýzu každého řezu sledovaným vzorkem. Tato práce je časově velmi nákladná a náročná na pozornost.

Z výše zmíněných důvodů vstupují do této oblasti metody zpracování obrazu, které přinášejí určitou míru automatizace. Umožňují provádět různé typy automatické segmentace a předzpracování dat, mohou zahrnovat nejrůznější prvky uživatelské interakce. Uživatel pak může provádět kontrolu správnosti, či odstraňovat chyby segmentace. Velmi užitečné jsou tyto postupy zejména pro zpracování velkého množství vzorků.

V reálných situacích často dochází k posuzování preparátů různé kvality. Vzorky obsahují různé typy artefaktů. To může být dáno okolnostmi odběru vzorku, případně jako důsledek jeho přípravy. Strojové zpracování takového materiálu pak může vykazovat velkou míru chybovosti. Časová náročnost identifikace a náprava takto vzniklých chyb pak přesáhne časovou úsporu vzniklou automatizací ([119]). Ostatní hodnoty jsou zjišťovány mnohem problematičtěji, jelikož vyžadují detailní sledování každé cévy napříč mnoha řezy .

Ruční metoda je velmi zdoluhavá a náročná na pozornost obsluhy. Proto jsme se rozhodli proces automatizovat za použití metod zpracování obrazu.

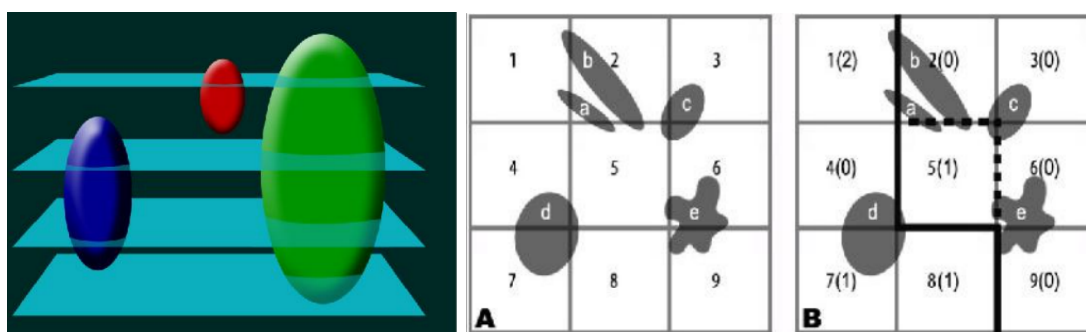
### 6.5.1 Volba oblasti zájmu

Kvantitativní studie z oblasti biologie v minulých dobách (70. léta 20. století) vycházely z obtížně ověřitelných předpokladů o tvarech hodnocených objektů. V případech, kdy se tyto předpoklady neshodovaly se skutečností, přicházela na řadu oprava prostřednictvím nejrůznějších korekčních faktorů. Až s využitím znalosti stochastické geometrie a teorie pravděpodobnosti došlo k rozvoji teoreticky lépe podložených metod. Ty jsou označovány jako „unbiased stereology“ a jejich rysem je potlačení rozdílu skutečné hodnoty od naměřené vlivem systematické chyby. S narůstajícím počtem měření tak ve studiích klesá rozptyl výsledků kolem skutečné hodnoty.

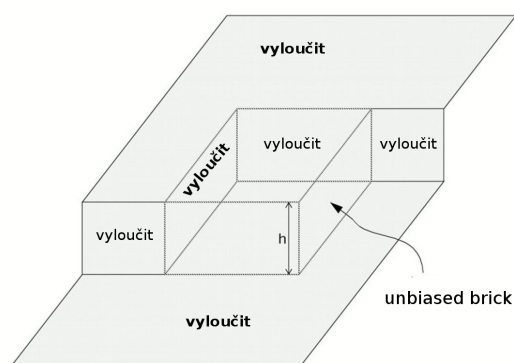
Jedním z problémů, který stereologie řeší, je počítání objektů v dvojrozměrných řezech. Objekty s různým tvarem mají odlišnou pravděpodobnost výskytu v rovině řezu. Například podlouhlé objekty s osou kolmou na osu řezu mají vyšší šanci na to, že budou v řezu zachyceny. Jde tedy o to, ve kterém záhytu objekt počítat. Problém je řešen v článku [113] principem disektoru. Podrobně to znázorňuje skupina obrázků 6.14. Na levé ilustraci je představena situace s podlouhlými objekty. Zbýlá dvojice ukazuje metodiku započítávání objektů pomocí disektoru. Objekty, které se jakkoliv dotýkají plné čáry disektoru, nejsou do sledované oblasti započteny. Čárkovaná linie pak dooznačuje tuto oblast. Objekty, které se jí dotýkají (a zároveň se nedotýkají plné čáry), jsou do oblasti zahrnuty. Více lze dohledat v [66].

Zobecnění pro trojrozměrné objekty představuje objemová sonda „Unbiased brick“. Její tvar ukazuje obrázek 6.15. Do cílového objemu jsou započítány objekty uvnitř pravoúhlé oblasti, které se však nedotýkají žádné z pěti vylučovacích ploch. Jen tak je možné zaručit měření nezatížené systematickou chybou.

## 6.5 Poloautomatická kvantitativní analýza tkáňových vzorků




**Obrázek 6.14:** Záchyt objektů v uvnitř disektoru. Levý obrázek znázorňuje problematiku záchytu objektů v závislosti na jejich tvaru. Další dvojice obrázků zobrazuje počítání objektů v devíti čtvercových oblastech. V závorce je uvedeno množství objektů započtených v dané oblasti. V oblasti s číslem pět je znázorněn disektor. Obrázky jsou převzaty z [66]



**Obrázek 6.15:** Objemová sonda „Unbiased Brick“, obrázek převzat a upraven z [39]

### 6.5.2 Měření parametrů cévního segmentu

Pro extrakci cévního systému je využíván algoritmus popsáný v části 6.1. Jednou z výhod využití 1D modelu je vyřešení potíží s plnou 3D reprezentací.



**Obrázek 6.16:** Měření délky. a) délka daná dvěma voxely b,c) větší délky měřené různými způsoby: 1) pixel to pixel 2) proložení polynomiální křivkou

Základním problémem je měření délky segmentu. Metody pro měření v našem případě využíváme dvě. První z nich odhaduje délku cévního segmentu jako součet vzdáleností středů voxelů. Tato metoda je na obrázku 6.16 reprezentována černou lomenou čarou. Situace označená písmenem *a* ukazuje cévní segment, který je reprezentován pouze dvojicí obrazových bodů. Zde je jediným dostupným prostředkem právě měření vzdáleností středů. Situace označená písmenem *b* ukazuje případ, kdy je tento způsob měření méně vhodný. V případech, kdy je to možné, proto provádíme náhradu hladkou křivkou. V naší implementaci byla použita B-spline křivka zavedená I.J. Schoenbergem ([104]). Z takto vytvořené reprezentace střednice cévy je pak vypočítávána délka.

Z výše zmíněných důvodů lze předpokládat, že průřez cévy je přibližně kruhový. Pomocí distanční transformace je vypočítána vzdálenost voxelů kostry daného úseku od nejbližšího okraje cévy. Tato informace je pak průměrována podél celého průběhu cévy.

### 6.5.3 Kvantitativní popis cévní mikrostruktury

Na základě diskuze s experty z oboru histologie jsme se rozhodli vytvořit systém pro automatické určování několika rozšířených histologických metrik. Jedná se o:

## 6.5 Poloautomatická kvantitativní analýza tkáňových vzorků

**Objemový podíl** ( $V_V$ ) (volume fraction, volume density), jedná se o podíl objemu zvoleného objektu v referenčním objemu. Pro nás tedy poměr objemu cév vztažený k jednotce objemu

**Povrchová hustota** ( $S_V[mm^{-1}]$ ) (surface density) popisuje velikost plochy na jednotku objemu. Pro nás se jedná o souhrnný povrch cévního systému v poměru k referenčnímu objemu

**Délková hustota** ( $L_V[mm^{-2}]$ ) (length density) délka lineárního útvaru vztažená k jednotce objemu. V našem případě tedy délka cévního řečiště v jednotce objemu.

**Numerická hustota** ( $N_V[mm^{-3}]$ ) (numerical density) počet objektů, které se nacházejí v jednotce objemu. Pro nás se jedná o počet větvení v poměru k objemu.

**Tortuosita** ( $Tort$ ) (tortuosity) je vyjádřena poměrem skutečné délky segmentu cévy a eukleidovskou vzdáleností jejího počátku a konce.

Pro kvantitativní hodnocení dat mikrostruktury je potřeba 1D model cévního stromu dále zpracovávat. Automaticky jsou odstraňovány krátké úseky, které vznikly jako důsledek šumu v trojrozměrných datech.

Po získání nasegmentovaných volumetrických dat a skeletonu cévního stromu lze přejít k samotné histologické analýze zkoumaného vzorku. Objemový podíl lze díky volumetrickým datům získat jako podíl počtu voxelů které jsou obsaženy v objemu cév a celkového počtu voxelů referenčního objemu.


V dalším zpracování je využíváno vyhodnocování jednotlivých cév. Pro každý cévní segment je k dispozici kostra a známe jeho délku. Ze znalosti všech délek a velikostí referenčního objemu lze vypočítat délkovou hustotu  $L_V$ . Pro výpočet tortuosity je navíc využita informace o počátku a konci každého segmentu. Celková tortuosita je pak určována jako průměr dílčích hodnot. Takto vypočtená tortuosita odpovídá výpočtu prostřednictvím jiného dostupného algoritmu Tort3D [69].

Měření povrchové hustoty je složitější proces. Využíváme sondu „Isotropic Fakir“ popsanou v [68]. Princip vychází z protnutí cílového objemu několika sondami ve tvaru jehly (viz obrázek 6.17). Výpočet povrchu je pak dán rovnicí, která hodnotí počet protnutí povrchu cílového objemu danou sondou:

$$\text{est}S = 2 \frac{1}{n} \sum_{i=1}^n \frac{v}{l_i} \cdot l_i \quad (6.6)$$

$n$  je zde počet sond,  $l_i$  je délka sondy,  $v$  je referenční objem a  $I_i$  je počet průsečíků sondy s měřeným objemem.

Výpočet počtu výskytů dělení byl odvozen od prostého počtu neterminálních uzlů. Výsledná data jak pro jednotlivé cévy tak pro celá data lze exportovat ve formátu CSV nebo YAML.



Obrázek 6.17: Sonda protíná 3D objekt, převzato z [68]

## 6.6 Vyhodnocení

V této kapitole byly představeny metody pro vytvoření geometrického modelu cévních systémů. Tyto modely jsou vytvářeny na základě trojrozměrných obrazových dat, která pocházejí zpravidla z lékařského CT nebo z MikroCT přístroje. Model cévního systému ve spojení s modelem tvaru parenchymu, který byl představen v Předchozí kapitole, umožňuje modelovat perfuzi parenchymatózního orgánu. To bylo publikováno v článku [8].

Dále byla vytvořena trojrozměrná reprezentace cévního systému prostřednictvím lineární algebraické reprezentace LAR. Metoda vytváření tohoto modelu byla publikována v článku [92].

Pro zachycení cévní mikrovaskulatury byl navržen systém, který vychází ze stereologických metod. Byly představeny metody pro kvantitativní popis cévního řečiště. V části 6.5.3 je popsána metoda používaná pro statistické hodnocení korizivních preparátů. Ta byla publikována v článku [4].

## Provedené experimenty

Obecným cílem této práce je vytváření algoritmů, které umožňují rozšiřovat poznání mechaniky prokrvování parenchymatózních tkání. V předchozím textu (v části 5.1) byl představen algoritmus pro vytvoření modelu tvaru takovéhoto orgánu. V části 6.1 je ukázána metoda pro vytvoření geometrického modelu cévního stromu. Dále bylo popsáno (v části 6.3) vytvoření statistického popisu cévní mikrostruktury. V této kapitole je zachycen soubor experimentů, které ověřují platnost těchto metod.

### 7.1 Testovací data


Vstupní data mají svůj původ v metodách výpočetní tomografie (CT), případně magnetické rezonance (MRI). CT bývá metodou první volby. Vyšetření je rychlejší, má vyšší prostorové rozlišení a je levnější. Magnetická rezonance je využívána v ojedinělých případech, často jako doplňkové vyšetření k CT. Výstupní rozlišení obou přístrojů závisí na řadě parametrů a liší se případ od případu.

Pro náš vývoj máme k dispozici 17 anonymizovaných CT snímků z Fakultní nemocnice v Plzni. Výhoda těchto dat je v možnosti získávat k nim dodatečné diagnostické informace. Data neobsahují výslednou požadovanou segmentaci. Ze stejného zdroje pak máme několik snímků břišní dutiny z magnetické rezonance. Jak bylo řečeno dříve, jedná se spíše o doplňkové vyšetření. Přesto se mu budeme v další práci věnovat.

Významným zdrojem, který využíváme je databáze SLIVER'07. Ta vznikla pro potřeby soutěže *MICCAI 2007 Grand Challenge*. Výstupy ze soutěže jsou publikovány v článku [50]. Dataset obsahuje dvacet CT snímků. Jejich rozlišení se v rovině řezu pohybuje od 0.5762 mm do 0.8125 mm. V ose těla je pak rozlišení v rozsahu od 0.7000 mm do 5.0000 mm. Průměrně obsahuje každá studie asi 208 řezů. Bližší statistiky o rozměrech voxelu a velikosti dat lze najít v tabulce 7.1. Tabulku doplňují grafy 7.2. Náhled těchto dat je možné vidět na obrázku 7.1, kde je zobrazen řez, který vede středem jater a segmentace, která je používána pro trénování a ověřování správnosti segmentačních metod.

Další dostupnou databází snímků břišní dutiny, která je vhodná pro náš výzkum, je 3D-IRCADb-01 ([111]). Je tvořena 20 případy, z nichž je 10 mužů a stejný počet žen.






**Obrázek 7.1:** Ukázka řezů játry v jednotlivých trojrozměrných snímcích z databáze SLIVER'07. Zelenou barvou je naznačena segmentace jater

	xy [mm]	z [mm]	xy [px]	z [px]
count	20.000000	20.000000	20	20.000000
mean	0.683242	1.622500	512	207.950000
std	0.068096	1.055122	0	94.194913
min	0.576172	0.700000	512	64.000000
25%	0.624512	1.000000	512	141.000000
50%	0.699609	1.000000	512	200.500000
75%	0.740723	2.000000	512	246.500000
max	0.812500	5.000000	512	394.000000


**Tabulka 7.1:** Statistické informace o datasetu SLIVER'07, rozměry obrazového bodu jsou uvedeny v milimetrech, rozměry v rovině řezu ( $xy$ ) a ose řezu ( $z$ ) jsou uvedeny v počtu obrazových bodů [ $px$ ]

## 7.2 Experimenty - makroskopický model parenchymu

Pacienti jsou v 75 procentech postiženi nádory jater.



**Obrázek 7.2:** Obrázky dokumentují statistické rozložení velikosti voxelu a velikosti jednotlivých obrázků v datasetu SLIVER'07




**Obrázek 7.3:** Ukázka datasetu 3D-IRCADb-01

## 7.2 Experimenty - makroskopický model parenchymu

S využitím dostupných trénovacích dat byla provedena řada experimentů, jejichž cílem je hledání vhodného nastavení parametrů segmentačního algoritmu. Jedním ze základních parametrů je velikost pracovního voxelu. Přepočítání na pracovní voxel umožňuje pracovat s heterogenními daty jednotným způsobem. Další výhodou je snížení výpočetních nároků metody Graph-Cut. Obrázek 7.4 ukazuje závislost mezi velikostí pracovního


## 7.2 Experimenty - makroskopický model parenchymu

voxelu a skóre vypočítaného metodikou SLIVER'07. Na levém obrázku jsou vyneseny jednotlivé metriky, obrázek vpravo zobrazuje vizualizaci kvartilů všech pomocí krabicevého grafu.



Obrázek 7.4: Závislost velikosti pracovního voxelu na úspěšnosti segmentace

Při použití segmentace pomocí metody Graph-Cut je zpravidla využíván parametr pro nastavení vah sousedních prvků grafu (N-linků). Při změně rozlišení však tento parametr mění svůj význam. V našem přístupu byl proto zaveden parametr  $\alpha$ , který je odvozen tak, aby kompenzoval velikost voxelu a byl tak nezávislý na rozlišení. Závislost skóre pro segmentaci jater na tomto parametru znázorňuje obrázek 7.5.

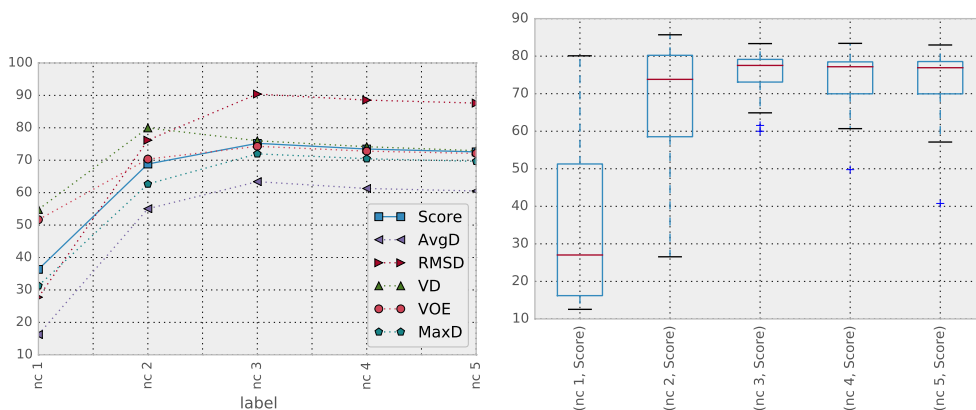


Obrázek 7.5: Závislost parametru  $\alpha$  na úspěšnosti segmentace

Součástí výpočtu je i vytvoření intenzitního modelu segmentovaného orgánu a pozadí. Oba modely jsou tvořeny gaussovskou směsí. Graf 7.6 ukazuje závislost na počtu komponent této směsi.


Slabinou naší segmentace, která je založena na grafových metodách, je vrozená

## 7.2 Experimenty - makroskopický model parenchymu



**Obrázek 7.6:** Závislost počtu komponent v intenzitním modelu popředí a pozadí na úspěšnosti segmentace

nepřesnost na okrajích, vzniklá převzorkováním na hrubší rozlišení. V dalším experimentu jsme ověřovali schopnost vylepšit segmentaci pomocí vyhlazování dat, které je popsáno v části 5.2.7. To zobrazuje první měření z obrázků 7.7. Další měření ukazují




**Obrázek 7.7:** Závislost úspěšnosti segmentace na apriorním zvětšení objemu


„rovnoměrné“ navyšování objemu podél povrchu segmentace. Postup je popsán v části 5.2.7

Apriorní zvětšování objemu nepřináší dostatečné vylepšení. V dalších experimentech byly ověřovány možnosti posprocessingu pomocí algoritmu MorphACWE, který je variantou Active Contour Model (viz část 5.2.7). Výsledky závislosti počtu iterací jsou vyobrazeny na obrázku 7.8. Případy s označením b1 03 a b1 05 zkoumají kombinaci MorphACWE a apriorního zvětšení objemu o 3%, respektive 5%.

## 7.2 Experimenty - makroskopický model parenchymu



Obrázek 7.8: Závislost počtu iterací MorphACWE na úspěšnosti segmentace



Obrázek 7.9: Závislost parametru  $\lambda_1$  MorphACWE na úspěšnosti segmentace

Metoda	síla řezu	velikost voxelu	naměřený objem
Syngo Volume	0.6 mm	$0.21 \times 0.21 \times 0.4$ mm	63.0 ml
LISA GC	5.0 mm	$0.21 \times 0.21 \times 5.0$ mm	63.0 ml
LISA GC	0.6 mm	$0.21 \times 0.21 \times 0.4$ mm	60.5 ml
Skutečný objem			60.0 ml

Tabulka 7.2: Měření reálného objemu

### 7.3 Kontrola měření objemu

V běžně prováděných experimentech, které evaluují přesnost metod měření objemu, je obvykle prováděno porovnání s jinou měřicí metodou, která je založena na zpracování stejných dat, avšak jiným způsobem. Zpravidla však není k dispozici nezávislá informace o skutečném objemu sledovaného objektu. Není tak možné odhalit chybu v měření, objevuje-li se v obou srovnávaných metodikách. Proto jsme provedli experiment, ve kterém známe přesný objem měřeného tělesa.

Cílem experimentu nebylo poukázání na nedostatky segmentační metody. Pro ověření jsme proto hledali objekty jednoduchého tvaru a s co možná nejvyšším kontrastem vůči pozadí.

Pro jeden experiment jsme použili injekční stříkačku naplněnou kontrastní látkou 7.10. Sledovali jsme objem kapaliny, jejíž reálný objem je 60ml. Pro měření byla použita data z výpočetní tomografie s rozměrem pixelu  $0.21 \times 0.21$ mm. Byly provedeny dvě rekonstrukce pro sílu řezu 0.6mm a 5mm (vzdálenost řezů 0.4 mm a 5 mm). Pro měření jsme použili námi navrženou segmentační metodu. Vzhledem k charakteru dat byla pracovní velikost voxelu zvolena  $1 \times 1 \times 1$ mm. Tuto metodu jsme porovnávali s poloautomatickou metodu v aplikaci Syngo Volume, která je běžně užívána pro volumetrická měření ve Fakultní nemocnici Plzeň.


První měření v aplikaci Syngo Volume bylo provedeno rekonstrukcí se vzdáleností řezů 0.6mm. Rozměr voxelu byl  $0.21 \times 0.21 \times 0.4$ mm.

A) Automatická segmentace na Syngo Volume.  $V=63$ ml, rekonstrukce: 0.6mm, voxel:  
 B) LISA -  $V=63$ ml, rekonstrukce z 5mm řezů, voxel LISA:  $1 \times 1 \times 1$ mm, zobrazení na původní  $0.21 \times 0.21 \times 5$ mm  
 C) LISA -  $V=60.5$ ml, rekonstrukce z 0.6mm řezů, voxel LISA:  $1 \times 1 \times 1$ mm, zobrazení na původní  $0.21 \times 0.21 \times 0.4$ mm

Druhým měřeným objemem byla skleněná lahev naplněná nejprve kontrastní látkou, podruhé vodou. V obou případech byl objem lahve shodně 710 ml. S kontrastní látkou byly vytvořeny dva snímky s vodou pak jeden. Tabulka 7.3 ukazuje výsledky měření. Směrodatná odchylka činí 18.43 a střední hodnota je 681.2 ml. Demonstruje to v hrubých rysech limity přesnosti měření založeného na snímku z výpočetní tomografie.

### 7.4 Víceměřítková Graph-Cut segmentace

V části 5.2.5 byla představena metoda víceměřítkové segmentace metodou Graph-Cut. Na tomto místě jsou představeny výsledky experimentů, které tuto metodu porovnávají




**Obrázek 7.10:** Porovnání měření objemu různými metodami A) Automatická segmentace na Syngo Volume.  $V=63\text{ml}$ , rekonstrukce:  $0.6\text{mm}$ , voxel:  $0.21 \times 2.21 \times 0.4\text{mm}$  B) LISA -  $V=63\text{ml}$ , rekonstrukce z  $5\text{mm}$  řezů, voxel LISA:  $1 \times 1 \times 1\text{mm}$ , zobrazení na původní  $0.21 \times 0.21 \times 5\text{mm}$  C) LISA -  $V=60.5\text{ml}$ , rekonstrukce z  $0.6\text{mm}$  řezů, voxel LISA:  $1 \times 1 \times 1\text{mm}$ , zobrazení na původní  $0.21 \times 0.21 \times 0.4\text{mm}$

snímek	popis	síla řezu	naměřený objem
	skutečný objem		710 ml
1	kontrast	5 mm	650 ml
2	kontrast	0.6 mm	690 ml
2	kontrast	5 mm	679 ml
3	voda	0.6 mm	693 ml
3	voda	5 mm	694 ml

**Tabulka 7.3:** Srovnání měření objemu lahve pomocí Syngo Volume

s výpočtem prostřednictvím běžné metody Graph-Cut (GC). Jsou zde dokumentovány přínosy mnou navržené metody.



**Obrázek 7.11:** Ukázka řezů jedním trojrozměrných testovacích obrazů


Experimenty byly provedeny na 140 umělých trojrozměrných obrazech (ukázku znázorňuje obrázek 7.11). V obraze, který je postižen šumem s gaussovským rozložením, se vždy nalézá objekt s odlišným jasnem. Objekty mají různou velikost obraz od obrazu. Seedy jednoho typu jsou umístěny uvnitř tohoto objektu, seedy druhého typu jsou umístěny vně objektu. Pole dat má krychlový tvar. Počet obrazových bodů na hraně krychle ( $\theta$ ) je různý. Cílem experimentu je ověřit schopnost algoritmu Multi-Scale Graph-Cut (MSGC) snižovat výpočetní a paměťové nároky.

Graf na obrázku 7.12 je zobrazuje porovnání doby výpočtu obou metod. Krabicové grafy s označením „total time“ ukazují celkové doby výpočtu. Z tabulky 7.4, která stejná data shrnuje číselně, je patrné, že celková doba výpočtu segmentace je příznivější pro metodu GC. Výpočet obou srovnávaných metod však lze rozdělit na část přípravnou, ve které dochází ke konstruování grafu, a část výkonnou, kde je prováděno hledání minimálního řezu. Data s označením „GC time“ a „MSGC time“ se zaměřují právě na tuto část. Zde je pak vidět, že metoda MSGC spotřebuje na svůj výpočet významně méně času.

Na obrázku 7.13 je zobrazena závislost počtu hran grafu, který je sestaven pro segmentaci, na velikosti testovacího obrazu. Je patrné, že pro metodu GC roste počet hran v grafu výrazně rychleji, než pro metodu MSGC.

S celkovým počtem hran úzce souvisí doba výpočtu řezu grafu, která je zachycena na dalším grafu 7.14 čárkovanou čarou. Je zde rovněž vidět, že celková doba výpočtu,






**Obrázek 7.12:** Porovnání doby výpočtu přímé metody Graph-Cut (Graph-Cut a víceměřítkové segmentace (MSGC))

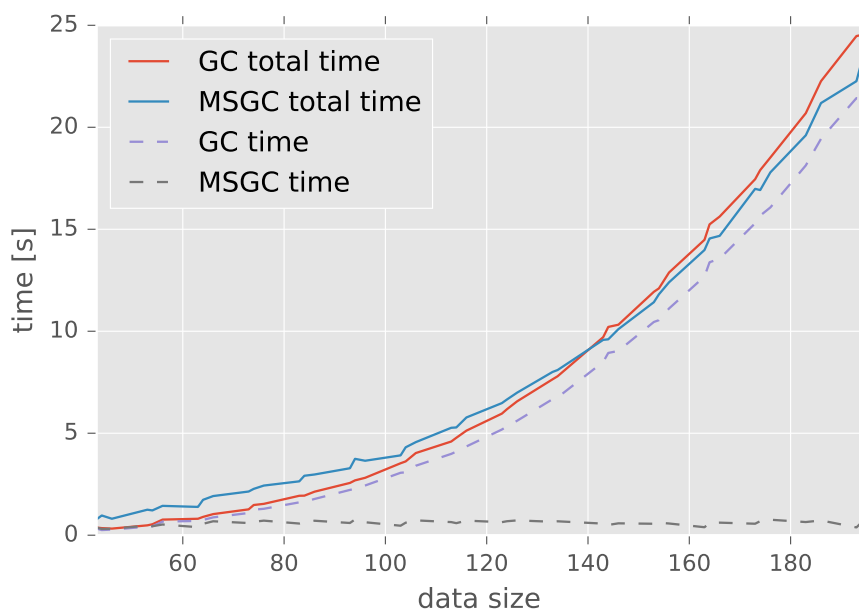
	GC total time	MSGC total time	GC time	MSGC time
count	140.000000	140.000000	140.000000	140.000000
mean	7.801908	9.872489	6.790169	1.777407
std	7.198799	10.857662	6.299495	4.440245
min	0.084727	0.225939	0.061310	0.070746
25%	1.523194	2.469998	1.284423	0.562746
50%	5.225047	6.565553	4.497626	0.635836
75%	13.441470	14.505819	11.724116	1.028397
max	24.524797	62.376001	21.430336	27.554826

**Tabulka 7.4:** Souhrn informací o délce výpočtu segmentace na celém datasetu. GC a MSGC označují jednotlivé metody. Popisek „total time“ označuje celkový čas výpočtu, zatímco ostatní časy informují o čisté době výpočtu řezu grafu

## 7.4 Víceměřítková Graph-Cut segmentace



**Obrázek 7.13:** Celkový počet hran v grafu při výpočtu segmentace prostřednictvím GC a MSGC. Velikost objektu je fixována



**Obrázek 7.14:** Doba výpočtu řezu grafu a celková doba výpočtu pro metody GC a MSGC

## 7.4 Víceměřítková Graph-Cut segmentace

	GC total time	MSGC total time	GC time	MSGC time
count	45.000000	45.000000	45.000000	45.000000
mean	7.601286	7.754637	6.610640	0.589016
std	7.276309	6.548372	6.373938	0.118371
min	0.323854	0.781632	0.252442	0.307736
25%	1.537281	2.434015	1.295487	0.558948
50%	4.776140	5.282953	4.098192	0.611518
75%	12.101039	11.811074	10.543419	0.682253
max	24.524797	23.196960	21.430336	0.771807

**Tabulka 7.5:** Souhrn informací o délce výpočtu segmentace na části datasetu, která obsahuje rozměrnější data s délkou hrany větší než 160. GC a MSGC označují jednotlivé metody. Popisek „total time“ označuje celkový čas výpočtu, zatímco ostatní časy informují o čisté době výpočtu řezu grafu


kteřá zahrnuje přípravnou i výkonnou část, je pro velké obrazy příznivější pro metodu víceměřítkové segmentace MSGC. Je zde také patrné, že podstatnou část celkové doby výpočtu pro tuto metodu zaujímá právě přípravná část. Ta je podstatně náročnější, než u metody GC. Jednou z příčin je komplexnost problému sestavování grafu, která je u této metody výrazně větší. Další příčinou zdržení je způsob implementace. Metoda GC má přípravnou část implementovanou v jazyce C. U metody MSGC byl použit jazyk Python a nebyly využívány žádné dodatečné optimalizace. Pro druhou část experimentu byla použita menší část původní testovací množiny. Data jsou vybrána tak, že segmentovaný objekt má vždy stejnou velikost (10903 voxelů). Mění se jen celková velikost trojrozměrného obrazu. Do výběru však byly zvoleny jen dostatečně velké obrázky, u kterých je délka jedné strany  $\theta$  větší než 160 obrazových bodů. Jeden z takových obrazů znázorňuje již vzpomínaný obrázek 7.11. Celkový počet vybraných dat je 45.

Výsledky měření jsou popsány tabulkou 7.5. Ta zachycuje délky výpočtů algoritmů GC i MSGC a shrnuje i čisté časy výpočtu algoritmu. Obrázek 7.15 pak stejná data shrnuje přehledněji formou krabicového grafu.

Ukazuje se tedy, že metoda MSGC je výhodná pro větší rozměry segmentovaných obrazů. Čím větší je oblast dat, tím více se přiklánějí měřené časy ve prospěch MSGC. Vliv má zjevně i velikost a tvar objektu. Čím má objekt menší povrch, tím více se uplatní časové úspory metody MSGC. Lze předpokládat, že s využitím dodatečných optimalizací v implementaci, dále vzroste účinnost metody MSGC.

Prostřednictvím párového t-testu byla ověřována hypotéza o rozdílné střední hodnotě celkových časů i časů výpočtu řezu grafu. Na hladině významnosti 99.95% ( $p = 0.0145$ ) byla zamítnuta nulová hypotéza o shodě středních hodnot časů výpočtů řez grafem v metodách GC a MSGC. Na hladině významnosti 99.95% ( $p = 7.48 \times 10^{-6}$ ) byla zamítnuta nulová hypotéza o shodě středních hodnot celkových časů GC a MSGC.

## 7.5 Texturní analýza kombinující Gabor-wavelety a Graph-Cut



**Obrázek 7.15:** Znázornění celkové délky výpočtu pro data s délkou hrany větší než 160. Mezi metodami Graph-Cut a MSGC je patrný rozdíl


## 7.5 Texturní analýza kombinující Gabor-wavelety a Graph-Cut

Metoda pro texturní segmentaci, která využívá dvoustrannou konvoluční strategii je popsána v části 5.2.6. Test probíhal na dvourozměrných obrazech textur, které zachycují textilie, dřevo a texturované povrchy. Porovnány byly metody prostého prahování a segmentace Gaborovými filtry. Ty zde slouží jako výchozí krok. Byly porovnávány s námi navrženými metodami. První z nich kombinuje Graph-Cut a Gaborovy wavelety (GFGC). Druhá tuto metodu rozšiřuje o dvoustrannou analýzu (TSGFGC).

Metoda	Chyba (%)
Prahování	6.01
Gaborovy Filtry	6.88
Gabor Filer Graph-Cut segmentation	7.54
Two-sided Gabor Filer Graph-Cut segmentation	0.94

**Tabulka 7.6:** Srovnání výsledků různých segmentačních metod

Metoda byla prověřena na 300 testovacích obrazech (viz obrázek 7.16) a porovnána s dalšími segmentačními metodami. Výsledky zachycuje tabulka 7.6. Kvůli texturní povaze testovacích dat by nemělo dopadnout prahování dobře. Dobrých výsledků bylo dosaženo díky tomu, že jednotlivé texturní povrchy měly velmi odlišný jas. Gaborovy



**Obrázek 7.16:** Ukázka textur použitých pro testování TSGFGC

filtry popisují texturu v celém svém okolí. Zvláště na okrajích segmentace pak dochází k chybám. GFGC je spojení Gaborových filtrů a metody Graph-Cut. Nejlepších výsledků dosahuje dvoustranný přístup k GFGC, který je přesný na okrajích segmentace. Obrázek 7.17 ukazuje příklad segmentace metod TSGFGC a GFGC. Dvoustranná analýza na levém obrázku zjevně nabízí lepší výsledek v situacích, kdy je tvar texturované plochy komplikovaný (například v rohu).

Nevýhodou tohoto přístupu je velká časová náročnost výpočtů. Ta pak významně limituje jeho praktické využívání pro interaktivní segmentaci. Je proto nezbytné hledat jiné cesty, jak extrahovat texturní příznaky z našich dat účinnější formou.

## 7.6 Texturní deskriptory pro parenchymatózní orgány


Povrch parenchymů zobrazených prostřednictvím výpočetní tomografie je společným projevem funkční hmoty parenchymu, kterým prostupuje cévní zásobenění. S cílem ověřit možnosti texturního popisu parenchymů bylo provedeno několik experimentů.

Pro sadu experimentů byla použita trénovací část datasetu SLIVER. Deset CT snímků s anotacemi bylo využito na trénování, stejně velký zbytek dat byl užít pro vyhodnocení. Velikost bloků byla zvolena  $50 \times 50 \times 10$ . Ověřovali jsme schopnost segmentace jater pomocí rozličných texturních popisů, které byly klasifikovány různými klasifikátory. Ověřováno bylo, zda najde uplatnění normalizace velikosti voxelu. Na obrázku 7.18 je ukázka výsledné segmentace pomocí příznakového vektoru tvořeného histogramem.


Celkově bylo spuštěno přes 60 různých konfigurací. Na výsledném grafu 7.19 jsou

## 7.6 Texturní deskriptory pro parenchymatózní orgány

---




Obrázek 7.17: Ukázka segmentace. Vlevo metoda TSGFGC, vpravo GFGC.



Obrázek 7.18: Ukázka segmentace pomocí texturního popisu. Příznakový vektor je tvořen z histogramu, klasifikátorem je Decision Tree

## 7.6 Texturní deskriptory pro parenchymatózní orgány



Obrázek 7.19: Výsledky segmentace pomocí texturní analýzy

vyneseny jen ty vybrané. Graf zobrazuje hodnoty celkového skóre dle metodiky SLIVER'07. V obrázku jsou použity následující zkratky. Příznakový vektor:

**fh** feature histogram,

**glcm** gray level co-ocurrence matrix

**gb** gabor filter

**lbp** local binary patterns

V některých případech byla využita kombinace několika přístupů. To je značeno symbolem +. Použité klasifikátory jsou značeny takto:

**dt** decision tree

**g** naive Bayes classifier

**lda** LDA Last part of acronym is the information about voxel

Poslední zkratkou je informace o normalizaci. Ta je označena písmenem *n*

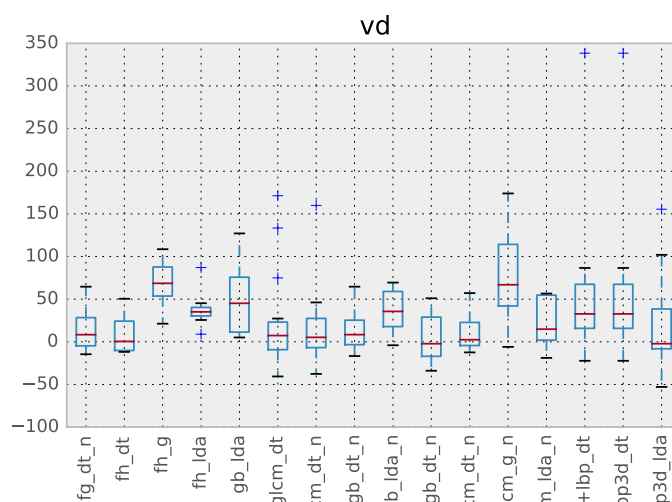
Metodika SLIVER07 je určena pro srovnání segmentačních algoritmů. V našem případě je však výsledkem segmentace hrubého rázu. Proto nejsou srovnání jednotlivých skóre nijak zvlášť vypovídající. Pro potřeby ořezu obrázku jednoduše není potřeba brát ohled například na střední vzdálenost segmentovaného povrchu od referenčních dat. Hlavní slabinou je však přepočítání skóre prostřednictvím srovnání s lidskou segmentací. Z toho důvodu je vhodné porovnávat přímo hodnoty vybraných metrik nepřepočtených na skóre. To ukazuje tabulka 7.7 a obrázek 7.20 zobrazuje další podrobnosti.

Nejllepší skóre z námi porovnávaných metod popisu získal přístup kombinující příznaky, které vychází z histogramu zkoumané oblasti a příznaky druhého řádu. Více

## 7.6 Texturní deskriptory pro parenchymatózní orgány

	Score	VD	VOE	AvgD	MaxD
label					
fg_dt_n	9.830525	15.105803	40.281922	18.431852	106.208282
fh_dt	9.932085	9.825606	38.784392	17.839859	122.436148
fh_g	0.770057	68.702124	39.557723	22.185131	131.089732
fh_lda	2.140093	38.477599	32.927878	16.334626	115.683357
gb_lda	4.935542	49.493635	46.390936	24.465287	140.610213
glcm_dt	7.323234	22.985396	66.647534	27.202673	135.641763
glcm_dt_n	8.307736	19.635898	73.780854	31.075880	138.867377
h+gb_dt_n	10.636285	14.092536	38.009582	17.423971	101.319452
h+gb_lda_n	6.454890	36.312909	35.022702	16.150603	97.716699
h+glcm+gb_dt_n	6.786381	4.276133	44.250782	16.153194	94.230806
h+glcm_dt_n	11.561401	11.328470	41.919859	17.944754	105.466048
h+glcm_g_n	2.082021	74.995925	43.443093	25.595057	132.635982
h+glcm_lda_n	11.048313	23.870686	33.777440	15.424118	96.023709
h+lbp_dt	3.588464	69.086731	75.294113	27.990631	141.208077
lbp3d+lbp3d_dt	3.588464	69.086731	75.294113	71.238919	265.581995
lbp3d+lbp3d_lda	8.128510	24.632933	63.128035	61.057433	263.762858

**Tabulka 7.7:** Hodnocení průměrů vybraných metrik pro segmentaci pomocí texturních příznaků



**Obrázek 7.20:** Výsledky segmentace pomocí texturní analýzy - objemová chyba (VD)



## 7.7 Kvantitativní popis mikrostruktury cévního řečiště jaterního parenchymu

label	Vv	Sv	Lv	Nv	Tort
b, agg=0.020	0.959354	0.016605	0.036658	0.009344	0.284503

Tabulka 7.8: Wilcoxonův test

různých klasifikátorů dosáhlo dobré skóre. Nejvyšší je pak klasifikátor využívající rozhodovací stromy. Po vizuální kontrole výstupních dat lze s jistotou prohlásit, že skóre není pro hrubou segmentaci vhodným ukazatelem. Výrazně větší vypovídací hodnotu má objemový podíl (VD). Z jeho srovnání vychází jako nejlepší volba kombinace histogramových příznaků a příznaků druhého řádu (GLCM) s Bayessovým klasifikátorem. Ta dosáhla shody v 74.0% segmentovaného objemu.

## 7.7 Kvantitativní popis mikrostruktury cévního řečiště jaterního parenchymu

Pro ověření správnosti navrženého postupu byla naměřena data na testovacím vzorku jaterní mikrostruktury. Jedná se o mikrokorozivní preparát prasečích jater, ze kterého byl odříznut menší vzorek a z něj byla nasnímána oblast o rozměru cca  $2 \times 2 \times 2\text{mm}$  s rozlišením  $1,875 \times 1,875 \times 1,875\mu\text{m}$  na voxel. Z těchto dat bylo dále zpracovááno 15 vybraných oblastí o rozměru cca  $350 \times 350 \times 50$  obrazových bodů. Pětice vzorků byla vybrána tak, aby obsahovala jaterní lalůček. Zbytek vznikl rozdělením náhodně vybraného sloupce o hraně  $350 \times 350$  na deset částí po padesáti řezech.

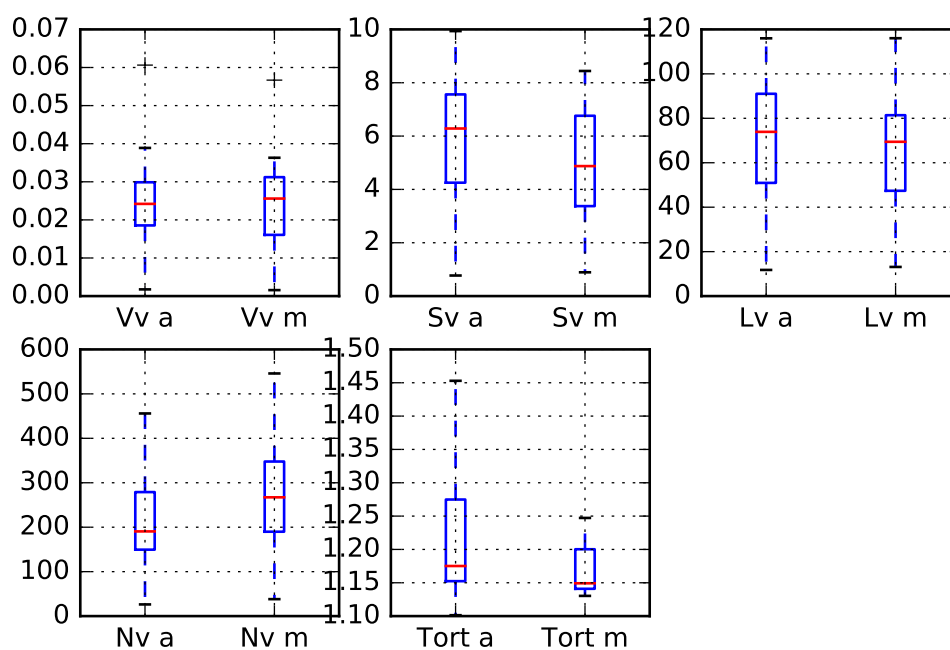
Na takto vzniklých vzorcích byly manuálně změřeny následující charakteristiky:

- poměrový objem
- poměrová plocha
- počet větvení vztažený k objemu
- poměrová délka
- tortuozita

Tato měření pak byla porovnána se strojově získávanými hodnotami. Poloměr slučování uzlů byl zvolen  $0,015\mu\text{m}$ . Testování je prováděno pomocí Wilcoxonova testu a Spearmanova koeficientu pořadové korelace [135]. Ověřována byla různá velikost poloměru uzlu. Naměřená data lze najít v přílohách 10.1 10.2 10.3 Výsledky statistických testů jsou zachyceny v tabulce 7.8 a 7.9. Jejich prostřednictvím se nám podařilo prokázat, že na hladině významnosti 0,05 není žádný signifikantní rozdíl mezi naší poloautomatickou metodou a manuální metodou.

## 7.8 Vyhodnocení experimentů

V této kapitole byla popsána řada experimentů dokumentujících posun poznání v automatizaci výzkumu parenchymatálních orgánů (zejména jater) prostřednictvím metod



**Obrázek 7.21:** Porovnání rozložení výsledků manuálního kvantitativního měření (m) s automatickým (a). Vv: poměrový objem, Sv: poměrová plocha, Nv: počet větvení vztážené k objemu, Tort: tortuozita

label	Vv	Sv	Lv	Nv	Tort
b, agg=0.020	0.009222	0.00222	0.000001	0.000392	0.854813

**Tabulka 7.9:** Spearmanův koeficient pořadové korelace

počítačového vidění. Dále byly ověřeny různé parametry nově navrhované segmentační metody a byly vyhodnoceny metodikou hodnocení navrženou v soutěži SLIVER'07'07. V rámci tohoto hodnocení bylo dosaženo 83.82 bodů, což odpovídá umístění třetího výzkumného týmu v žebříčku soutěže. Byla ověřena metoda automatického navrhování seedů, která snižuje zátěž obsluhy. Navrženo bylo rozšíření metody Graph-Cut o víceměříkovou variantu. Dle experimentů bylo prokázáno zvýšení rychlosti výpočtu pro data s velkým počtem obrazových bodů.

Experimenty prokázaly schopnost dvoustranné texturní analýzy TSGFGC v obecné segmentační úloze dobře pracovat s texturovanými povrchy zejména na okraji segmentované plochy. Nepodařilo se však prokázat významný přínos texturních popisů pro vylepšení kvality segmentace parenchymatózních orgánů.

V oblasti modelování cévního stromu parenchymů byla srovnána běžná metodika popisování korozivních preparátů cévního systému jater s námi navrhovanou metodou. Měřena byla objemová hustota ( $L_V$ ), povrchová hustota ( $S_V$ ), počet větvení cévy ( $N_V$ ) a tortuositá. Bylo prokázáno, že neexistuje statisticky významný rozdíl mezi měření provedeným manuální metodou a měřením, která jsou provedena námi navrženým automatem. Článek s popisem metody a výsledky experimentů je přijat k publikaci v časopise „International Journal of Computer Assisted Radiology and Surgery“.

## 8

# Aplikační přínos

V předchozím textu byly podrobně rozebrány návrhy metod pro modelování parenchymatózních orgánů a jejich cévních systémů. Následující text jednotlivé položky stručně shrnuje.


## 8.1 Segmentace parenchymatózních orgánů

V práci byla představena metoda pro segmentaci parenchymů v břišní dutině. Na základě původních článků [13, 14] jsme navrhli výpočty obou typů hran grafu a vytvořili interaktivní uživatelské rozhraní v prostředí Matlab, které umožňuje na základě jednoduchého uživatelského vstupu segmentovat libovolný barevný i černobílý obraz. Uživatelem označené seedy jsou užity k natrénování modelu popředí a pozadí. Model je tvořen gaussovskou směsí, která je nastavována pomocí EM algoritmu.

Pro potřeby diagnostiky byl vytvořen systém k měření střední denzity a velikosti označené oblasti. Vstupem byla jednokanálová data z CT a MRI ve formát DICOM. Bylo nutné respektovat určitá specifika výstupů přístrojů. Systém byl navržen podobným způsobem jako v předešlém případě. Objekt a pozadí bylo modelováno gaussovskou směsí na základě uživatelského označení. Nad obrazovými body nasegmentovaného objektu pak bylo provedeno měření požadovaných veličin. Článek popisující systém byl publikován na konferenci Medtech (viz [7]).

Metoda využívající Graph-Cut byla dále implementována v jazyce Python a představena na konferenci ([3]). Metoda byla dále rozšířena o použití příznakového vektoru, který vychází z umístění voxelu uvnitř těla vzhledem k významným tkáňovým strukturám. Dále je prováděno dodatečné zpracování prostřednictvím Active Contour Model. Byla navržena metoda pro snížení výpočetních nároků prostřednictvím víceměřítkové segmentace. Konkrétní podrobnosti lze čerpat v části

Segmentační metoda byla doplněna o uživatelské rozhraní, které umožňuje pracovat s trojrozměrnými daty. Obrázek 8.1 toto rozhraní ukazuje. Modul je včetně zdrojových kódů volně dostupný ( <https://github.com/mjirik/pysegbase> ).

Obrázek 8.1: Segmentace modulem *pysegbase*

## 8.2 Aplikace Lisa

V rámci spolupráce s Fakultní nemocnicí Plzeň byla vytvořena aplikace Lisa. Tato platforma využívá algoritmy a poznatky získané nejen touto prací. Její rozhraní je vyvíjeno na základě zpětné vazby uživatelů. V současnosti umožňuje provádění měření objemu parenchymů. Dále lze studovat cévní stromy v segmentovaných orgánech. Pro potřeby jaterní chirurgie je zde k dispozici nástroj pro vytváření virtuálních resekcí. Ten umožňuje odhadnout velikost resektátu v průběhu předoperačních vyšetření.

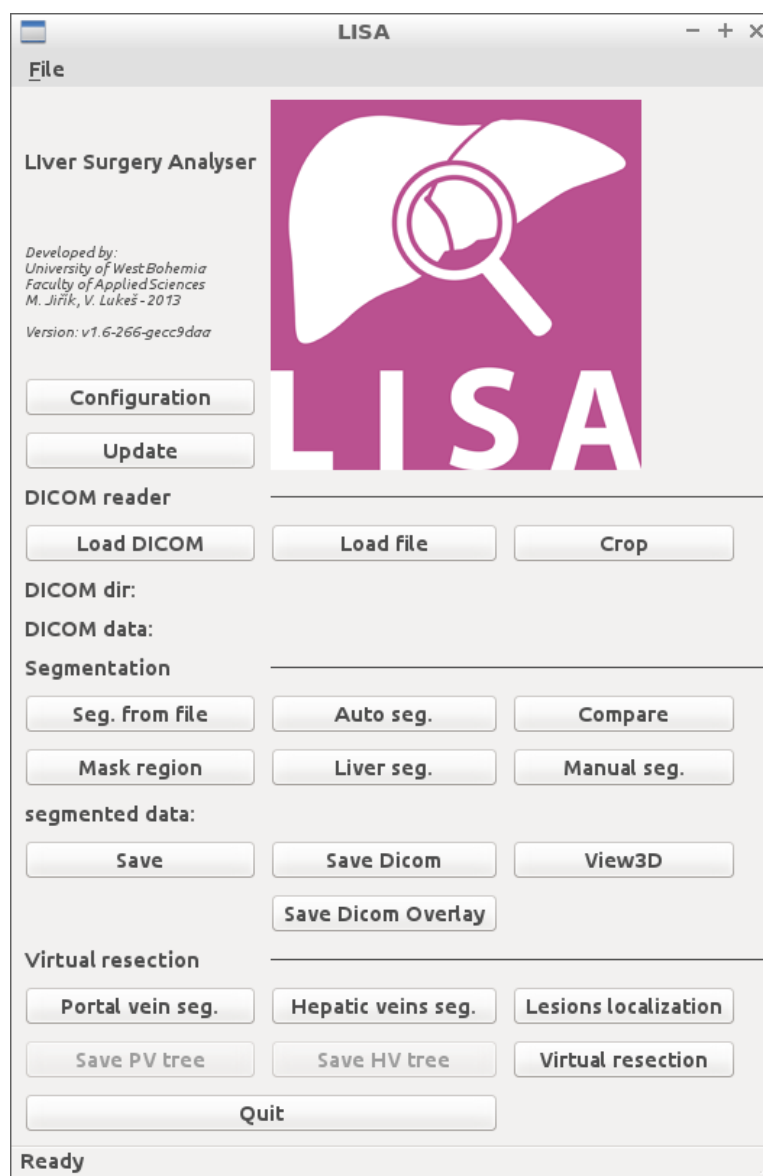
Do budoucna je plánováno nasazování aplikace do klinické praxe a rozšiřování jejích možností. Aplikace je volně dostupná ( <https://github.com/mjirik/lisa> ).

## 8.3 Aplikace QuantAn

Pro modelování perfuze jaterního parenchymu je nezbytnou složkou geometrický model cévního systému. Aplikace QuantAn vznikla jako odpověď na velkou časovou náročnost manuálního kvantitativního hodnocení vzorků jaterní mikrovaskulatury. Obrázek 8.3 ukazuje několik snímků uživatelského rozhraní. Je na něm zachycena obrazovka pro načítání dat, kontrola provedené skeletonizace a vizualizace výsledků. Popis aplikace byl zveřejněn v článku [4]. Aplikace samotná je volně dostupná včetně zdrojových kódů ( <https://github.com/mjirik/quantan> ).

## 8.4 Další moduly

Souběžně s prací na disertační práci jsem vyvinul řadu modulů, které je možné opakovaně využívat pro další výzkumné práce. Většina funkcionalita je vytvořena v jazyce



Obrázek 8.2: Aplikace Lisa

## 8.4 Další moduly

**QuantAn**

**Load Data:**

Load directory (DICOM)    Load file    Generated data

Data path: /home/mjrnk/data/medica/orig/jatra\_mikro\_data/597-647c.tif  
Data info: 51x250x300, [1.0, 1.0, 1.0]

Manual voxel size    Z: 0.004682    Y: 0.004682    X: 0.004682  
 Manual crop data    Z:    Y:    X:     
 GUI Crop data

Continue

---

Ready

**Finished**

Vessel volume fraction (Vv):	0.206401992357 [-]	Total vessel length:	40.6880726765 [mm]
Surface density (Sv):	30.2856166612 [mm <sup>-1</sup> ]	Average vessel length:	0.0849437842934 [mm]
Length density (Lv):	344.487757176 [mm <sup>-2</sup> ]	Average vessel radius:	0.0103949333047 [mm]
Tortuosity:	1.30775986761 [length/distance]	Vref:	0.118111810446 [mm <sup>3</sup> ]
Nv:	1690.07748723 [mm <sup>-3</sup> ]		

**Radius histogram**

**Length histogram**

Label/Comment:

Write details to YAML    Write report to YAML    Save segmentation  
Write details to CSV    Write report row to CSV    Save labeled skeleton

Finished

Obrázek 8.3: Ukázka rozhraní aplikace QuantAn

Python. Ve většině případů lze moduly instalovat standardně pomocí nástroje `pip` distribučního kanálu Python Package Index (PyPI). Alternativním způsobem instalace je nástroj `conda` distribučního systému Anaconda [4].

dispozici jsou zdrojové kódy jednotlivých funkcionalit, moduly je možná k

`skelet3d` modul pro vytvoření kostry z trojrozměrných objemových dat. <https://github.com/mjirik/skelet3d>

`io3d` modul pro jazyk python, který zajišťuje načítání trojrozměrných dat z rozličných souborových formátů. Na pozadí využívá moduly `SimpleITK`, které dále rozšiřuje. <https://github.com/mjirik/io3d>

`sed3` je editor pro zobrazování řezů 3D objemových dat. Umožňuje označování zájmových bodů, změnu okna zobrazovaných intenzit, volbu roviny pohledu a vizualizaci zadaných objemů (například výsledku segmentace). <https://github.com/mjirik/sed3>

`imtools` balík funkcí pro práci s trojrozměrnými daty. <https://github.com/mjirik/imtools>

`larVolumeToObj` balík pro import trojrozměrných objemových dat do systému LAR. Balík vznikl úpravou skriptů projektu `lar-runng-demo` <https://github.com/mjirik/larVolumeToObj>



## 9

# Závěr

Vytváření modelu geometrie parenchymatózních orgánů tkví ve zkoumání dat z různých zdrojů. Hlavním cílem je vymezení objemu parenchymu, vytvoření popisu polohy a tvaru orgánu, ale i popis jeho cévních struktur v rozličném měřítku. To zahrnuje jak velké cévy s průsvitem několika milimetrů, tak i cévy s průměrem v řádu mikrometrů. Takový model má zásadní význam při zkoumání vlastností parenchymu, neboť umožňuje další zkoumání procesů v orgánu prostřednictvím modelování proudění krve v cévách.

Uplatnění nachází modelování ve dvou oblastech. Tou první je klinická medicína, ve které je cílem přímo zlepšovat kvalitu lékařských zákroků prostřednictvím zdokonalování předoperačního procesu. Aplikací modelů vzniklých technikami strojového učení je možné automatizovat činnost některé procedury předoperačních vyšetření a snižovat tak mentální zátěž ošetřujícího personálu. Druhou oblastí je výzkum kvality parenchymu. Zde vytváří modelování základ pro studium parenchymu. Cílem je zde hodnocení geometrických vlastností. To je prováděno prostřednictvím statistických metod, které vycházejí z oboru stereologie. Na geometrický model je dále navázáno modelem proudění krve.

Sestrojení modelu je z pohledu strojové analýzy posloupností několika kroků. Prvním krokem, je obrazová segmentace parenchymatózního orgánu, následovaná obrazovou segmentací cévních systémů. Dalším úkonem je pak analýza takto vytvořených dat a generování modelu. Konkrétní podoba je pak závislá na účelu, pro který je model vytvářen.

Na Fakultě aplikovaných věd vznikla ve spolupráci s Lékařskou fakultou v Plzni Univerzity Karlovy v Praze skupina, která zaměřuje svůj dlouhodobý výzkumný plán do oblasti klinické (a zejména chirurgické) léčby jater. Jedním z důležitých faktorů, které určují funkci a anatomii tohoto orgánu je anatomie cévního stromu. Metody navrhované v této práci jsou proto experimentálně ověřovány právě na analýze jater. Jejich platnost se však na tento orgán neomezuje a lze ji rozšířit i na ostatní parenchymatózní orgány, ale i na nehumánní experimentální modely.

## 9.1 Dosažené cíle

Provedme nyní kontrolu splnění těchto cílů, které byly stanoveny v úvodu této práce a řešeny v částech 5.1 a 6. Obecným záměrem práce bylo vytvoření metod pro podporu rozšíření poznání perfuzních procesů uvnitř parenchymů. Naplnění konkrétních bodů je rozebráno v dalším textu včetně odkazů na vytvořené publikace. Publikační pokrytí je však širší. Výsledky práce například přispěly k vytvoření monografie [7].

### 9.1.1 Segmentace parenchymu

Byla navržena metoda interaktivní segmentace parenchymatózniích orgánů, která byla rozšiřována do souboru několika aplikací. Ty směřují k využívání v klinické praxi, ale i výzkumné činnosti, která se týká parenchymu jater. Vytvořili jsme nástroj pro virtuální resekci jater. Ten umožňuje usnadňovat předoperační vyšetření a přináší nové možnosti do procesu volby operační strategie.

Výsledky experimentů ukazují, že navržená metoda víceměřítkové segmentace urychluje výpočet metodou Graph-Cut pro objemová data, ve kterých je hledaný objekt kompaktní a zaujímá menší část objemu. To je situace typická pro parenchymatózniích orgány.

Na konferenci *International Conference on Pattern Recognition and Image Analysis: New Information Technologies* byl publikován příspěvek [3], který popisuje metodu pro segmentaci jaterního parenchymu.

### 9.1.2 Model cévního systému

Na základě diskuze a společné práce s odborníky na modelování proudění byl navržen model proudění v cévním stromu. Každý segment cévního systému je v tomto modelu nahrazen zobecněným válcem. Já jsem navrhl metody pro extrakci geometrických parametrů z objemových obrazových dat. V tomto procesu dochází k segmentaci objemu cévního systému, zjednodušení tvaru a detekce větvení. Dále je prováděn odhad parametrů segmentu (délka, průměr, atd.).

Vytváření modelu cévního stromu je popsáno v části 6.1. Model je pak využíván v navazující části pro výpočet perfúze. Vytvoření trojrozměrné reprezentace cévního systému prostřednictvím lineární algebraické reprezentace LAR bylo publikováno ([92]) v časopise *Computer-Aided Design*.

### 9.1.3 Geometrický model pro modelování prokrvení

Cílem této práce bylo navržení metodiky pro vytváření geometrických modelů parenchymatózniích orgánů a jejich cévního systému s respektováním potřeb modelování prokrvení. Tento cíl byl naplněn spojením modelu námi navrženého modelu cévního systému a modelu parenchymu.

Navrhl jsem metody pro extrakci geometrických parametrů obou modelů z trojrozměrných obrazových dat. Využívá se vymezení parenchymu prostřednictvím mnou navržené segmentace. Model cévního systému interaktivně získáván ze stejných dat.

Navrhl jsem metodu pro zjednodušení reprezentace cévního stromu, která vyhovuje potřebám matematického modelování proudění. Model je popisován v části 6.2.3. Práce, která tento model využívá, jsme publikovali v článku [8].

### 9.1.4 Kvantitativní popis jaterní mikrostruktury

V části 6.3 je popsána metodika kvantitativního hodnocení jaterní mikrostruktury. Experimenty bylo prokázáno, že navržená metoda poskytuje hodnocení korozivních preparátů tkáňových vzorků pro vybrané metriky nerozlišitelné od manuálního měření. Tento výsledek byl publikován v časopise *International Journal of Computer Assisted Radiology and Surgery*.

## 9.2 Navazující výzkum

V navazujícím výzkumu budou zde navržené algoritmy a procedury dále vyvíjeny. V nejbližší době plánujeme využití konvolučních neuronových sítí pro potřeby vytváření intenzitního a polohového modelu parenchymů. Dále plánujeme vylepšit implementaci víceměřítkové segmentace Graph-Cut tak, aby byla zrychlena fáze konstrukce grafu.

V delším časovém horizontu má naše skupina v plánu vytvoření metodiky pro predikci regenerace jaterního parenchymu po resekcčním zákroku. Cílem je předvídat míru regenerace jednotlivých částí jater. To bude mít dopad na volbu léčebné metody. Pro provedení tohoto plánu je nezbytné porozumět jaterní mikrostruktuře. Za tímto účelem na pracovištích Lékařské fakulty v Plzni prováděn výzkum na experimentálních zvířatech, zejména na praseti domácím. Další vývoj bude proto orientován s ohledem na zvířecí model, kterým je pro výzkum využíván. Metody využívané v humánní medicíně budou zobecněny pro použití na experimentálních zvířatech. Algoritmy pro zpracování obrazu tak budou respektovat anatomická specifika daného modelu.

# Literatura

- [1] Ústav zdravotnických informací a statistiky ČR (<http://www.uzis.cz/>). xii, 5, 6
- [2] Álvarez, L.; Baumela, L.; Márquez-Neila, P.: Morphological Snakes. *Inteligencia Artificial*, 2010. 84
- [3] Ambrose, J.: Computerized transverse axial scanning (tomography): Part 2. Clinical application\*. *The British journal of radiology*, ročník 46, č. 552, 1973: s. 1023–1047. xii, 22
- [4] Analytics, C.: Anaconda. 2016. 128
- [5] Arish, A.; Eshkenazy, R.; Bismuth, H.: Milestones in the evolution of hepatic surgery. *Rambam Maimonides Medical Journal*, ročník 2, č. 1, 2011: s. 1–11, ISSN 2076-9172, doi:10.5041/RMMJ.10021. 16
- [6] Aurenhammer, F.; Klein, R.: Handbook of Computational Geometry . 2000. 43, 44
- [7] Baddeley, A.; Jensen, E. B. V.: *Stereology for statisticians*. Chapman & Hall/CRC Boca Raton, Fla. ; London, 2005, ISBN 1584884053, 395 p. : s. 97
- [8] Basak, T.: Combinatorial cell complexes and Poincaré duality. *Geometriae Dedicata*, ročník 147, č. 1, 2010: s. 357–387, ISSN 00465755, doi:10.1007/s10711-010-9458-y, 0807.4165. 89
- [9] Bayer, T.: Detekce kartografického zobrazení z množiny bodů. *Geodetický a kartografický obzor*, ročník 2, 2008: s. 10–15. 43
- [10] Bonthius, D. J.; Stanek, N.; Grose, C.: Subacute sclerosing panencephalitis, a measles complication, in an internationally adopted child. *Emerg Infect Dis*, ročník 6, č. 4, 2000: s. 377–381, ISSN 1080-6040. 26
- [11] Bovik, A. C.; Clark, M.; Geisler, W. S.: Multichannel Texture Analysis Using Localized Spatial Filters. *IEEE Trans. Pattern Anal. Mach. Intell.*, ročník 12, č. 1, 1990: s. 55–73, ISSN 0162-8828, doi:10.1109/34.41384. 56

- 
- [12] Boykov, Y.; Jolly, M.-P.: Interactive Organ Segmentation Using Graph Cuts . *MICCAI '00: Proceedings of the Third International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2000: s. 276–286. 65
- [13] Boykov, Y.; Kolmogorov, V.: An Experimental Comparison of Min-cut/Max-flow Algorithms for Energy Minimization in Vision. *IEEE transactions on pattern analysis and machine intelligence*, ročník 26, č. 9, sep 2001: s. 359–374, ISSN 0162-8828, doi:10.1109/TPAMI.2004.60. 61, 63, 65, 124
- [14] Boykov, Y.; Veksler, O.; Zabih, R.: Efficient Approximate Energy Minimization via Graph Cuts. *IEEE transactions on Pattern Analysis and Machine Intelligence*, ročník 20, č. 12, 2001: s. 1222–1239. 61, 64, 83, 124
- [15] Boykov, Y.; Veksler, O.; Zabih, R.: Fast approximate energy minimization via graph cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 23, č. 11, 2001: s. 1222–1239, ISSN 01628828, doi:10.1109/34.969114. 79, 81
- [16] Boykov, Y. Y.; Jolly, M. P.: Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images. *Computer Vision, 2001. ICCV 2001. Proceedings. Eighth IEEE International Conference on*, ročník 1, 2001: s. 105–112. 79, 81
- [17] Brodatz, P.: *Textures: a photographic album for artists and designers*. Dover Publications Inc., 1966. 39, 58
- [18] Canny, J.: A Computational Approach to Edge Detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, ročník PAMI-8, č. 6, 1986: s. 679–698, ISSN 01628828, doi:10.1109/TPAMI.1986.4767851. 60
- [19] Čihák, R.: Anatomie 2. 2002. xii, 9, 11, 12
- [20] Čihák, R.: Anatomie 3. 2002. 9, 90
- [21] Connors, R. W.; Harlow, C. A.: A Theoretical Comparison of Texture Algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník PAMI-2, 1980: s. 204–222. 35, 57
- [22] Couinaud, C.: *Le foie: {études anatomiques et chirurgicales}*. Masson et Cie, 1957. 16
- [23] Cross, G. R.; Jain, A. K.: Markov Random Field Texture Models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník PAMI-5, 1983: s. 25–39, doi:10.1109/TPAMI.1983.4767341. 48
- [24] Dana, K. J.; Van-Ginneken, B.; Nayar, S. K.; aj.: Reflectance and Texture of Real World Surfaces. *ACM Transactions on Graphics (TOG)*, ročník 18, č. 1, jan 1999: s. 1–34. 58

- [25] Daugman, J.: Two-dimensional spectral analysis of cortical receptive field profiles. *Vision Research*, ročník 20, č. 10, 1980: s. 847–856. 53
- [26] Davis, L. S.; Clearman, M.; Aggarwal, J. K.: A Comparative Texture Classification Study Based On Generalized Cooccurrence Matrices. In *IN IEEE CONF. ON DECISION AND CONTROL*, Springer-Verlag, 1979, s. 12–14. 42
- [27] Debbaut, C.: *Muliti-level Modelling of Hepatic Perfusion in Support of Liver Transplantation Strategies*. Dizertační práce, Ghent University, 2013. 90, 94
- [28] Debbaut, C.; Monbaliu, D.; Casteleyn, C.; aj.: From vascular corrosion cast to electrical analog model for the study of human liver hemodynamics and perfusion. *IEEE transactions on bio-medical engineering*, ročník 58, č. 1, jan 2011: s. 25–35, ISSN 1558-2531, doi:10.1109/TBME.2010.2065229. 90, 94
- [29] Dempster, A.; Laird, N.; Rubin, D.: Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society. . . .*, ročník 39, č. 1, 1977: s. 1–38. 79
- [30] Du Bois, D.; Du Bois, E. F.: Clinical calorimetry: tenth paper a formula to estimate the approximate surface area if height and weight be known. *Archives of internal medicine*, ročník 17, č. 6\_2, 1916: s. 863–871. 67
- [31] Duda, R. O.; Hart, P. E.: Use of the Hough transformation to detect lines and curves in pictures. *Commun. ACM*, ročník 15, jan 1972: s. 11–15. 60
- [32] Dušek, L.; Mužík, J.; Kubásek, M.; aj.: Český národní webový portál epidemiologie nádorů, . Verze 7.0. 2007. xii, 5, 6
- [33] Dušek, L.; Mužík, J.; Pavlík, T.; aj.: Epidemiologie zhoubných nádorů trávicího traktu v České republice–současný stav a predikce. *Gastroent Hepatol*, ročník 66, č. 5, 2012: s. 331–339. 5
- [34] Eberlová, L.: *Studium morfologie aneuryzmatu břišní aorty*. Dizertační práce, Univerzita Karlova v Praze, 2013. xiv, 95, 96
- [35] Eliáš, P.; Máca, P.; Neuwirth, J.; aj.: *Moderní diagnostické metody: Výpočetní tomografie II.díl*. díl 2, Institut pro další vzdělávání pracovníku ve zdravotnictví Brno, 1998. 21, 22
- [36] Felekouras, E. S.; Kaparelos, D. C.; Papalambros, E.: The history of liver surgery, hepatectomy and haemostasis. *Hellenic Journal of Surgery*, ročník 82, č. 5, 2010: s. 280–296, ISSN 0018-0092, doi:10.1007/s13126-010-0046-2. 16
- [37] Ferda, J.; Flohr, T.; Schmidt, B.; aj.: Detekce intrakraniálního krvácení: srovnání virtuálního nativního zobrazení při CT-angiografii mozku pomocí duální energie záření a „konvenčního“ nativního CT. *Česká radiologie*, ročník 62, č. 4, 2008: s. 395–402. xii, 22

- [38] Ferda, J.; Novák, M.; Kreuzberg, B.: *Výpočetní tomografie*. GALÉN, 2002, 663 s. 20
- [39] Fiala, J. C.; Harris, K. M.: Extending Unbiased Stereology of Brain Ultrastructure to Three-dimensional Volumes. *Journal of American Medical Information Association*, ročník 8, č. Januar, 2001: s. 1–16, ISSN 1546-1726, doi:10.1038/nn0213-111. xiv, 100
- [40] Fisher, R. A.: The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, ročník 7, č. 2, sep 1936: s. 179–188, ISSN 20501420, doi:10.1111/j.1469-1809.1936.tb02137.x. 75
- [41] Gabor, D.: Theory of Communication. *J. Inst. Elect. Eng.*, ročník 93, 1946: s. 429–457. 53
- [42] Galloway, M.: Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*, ročník 4, č. 2, 1975: s. 172–179. 34
- [43] Geisser, S.: Posterior odds for multivariate normal classifications. *Journal of the Royal Statistical Society. Series B (Methodological)*, 1964: s. 69–76. 75
- [44] Giuvărășteanu, I.: Scanning electron microscopy of vascular corrosion casts—standard method for studying microvessels. *Romanian journal of morphology and embryology = Revue roumaine de morphologie et embryologie*, ročník 48, č. 3, 2007: s. 257–261, ISSN 12200522. 94
- [45] Gregor, T.; Kochová, P.; Eberlová, L.; aj.: Correlating Micro-CT Imaging with Quantitative Histology. *Injury and Skeletal Biomechanics*, 2012, doi:http://dx.doi.org/10.5772/48680. 86
- [46] Grieg, D. M.; Porteous, B. T.; Scheult, A. H.: Exact maximum a posteriori estimation for binary images. *Journal of the Royal Statistical Society*, ročník 51, č. 2, 1989: s. 271–279. 61
- [47] Grigorescu, S. E.; Petkov, N.; Kruizinga, P.: Comparison of texture features based on Gabor filters. *IEEE Trans. on Image Processing*, ročník 11, č. 10, 2002: s. 1160–1167. 57
- [48] Haralick, R. M.: Statistical and structural approaches to texture. *Proceedings of the IEEE*, ročník 67, č. 5, may 1979: s. 786–804, ISSN 0018-9219, doi:10.1109/PROC.1979.11328. 28
- [49] Haralick, R. M.; Shanmugam, K.; Dinstein, I.: Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, ročník 3, č. 6, 1973: s. 610–621. 30

- [50] Heimann, T.; van Ginneken, B.; Styner, M. a.; aj.: Comparison and evaluation of methods for liver segmentation from CT datasets. *IEEE transactions on medical imaging*, ročník 28, č. 8, aug 2009: s. 1251–65, ISSN 1558-254X, doi:10.1109/TMI.2009.2013851. 104
- [51] Homann, H.: Implementation of a 3D thinning algorithm. *The Insight Journal*, ročník July - Dec, 2007. 87
- [52] Houdek, R.: *Metodika stanovení parametrů hierarchického modelu jaterní perfúze s využitím obrazové analýzy medicínských dat*. Dizertační práce, University of West Bohemia, 2015. 92
- [53] Hu, M.-K.: Visual pattern recognition by moment invariants. *Information Theory, IRE Transactions on*, ročník 8, č. 2, 1962: s. 179–187, ISSN 0096-1000, doi:10.1109/TIT.1962.1057692. 37
- [54] Hyde, E. R.; Cookson, A. N.; Lee, J.; aj.: Multi-scale parameterisation of a myocardial perfusion model using whole-organ arterial networks. *Annals of Biomedical Engineering*, ročník 42, č. 4, 2014: s. 797–811, ISSN 15739686, doi:10.1007/s10439-013-0951-y. 92
- [55] Hyde, E. R.; Michler, C.; Lee, J.; aj.: Parameterisation of multi-scale continuum perfusion models from discrete vascular networks. *Medical and Biological Engineering and Computing*, ročník 51, č. 5, 2013: s. 557–570, ISSN 01400118, doi:10.1007/s11517-012-1025-2. 92
- [56] Jain, A. K.; Farrokhnia, F.: Unsupervised texture segmentation using Gabor filters. In *Systems, Man and Cybernetics, 1990. Conference Proceedings., IEEE International Conference on*, 1990, s. 14–19, doi:10.1109/ICSMC.1990.142050. 56
- [57] Janžura, M.; Otáhal, A.: Náhodná pole a jejich aplikace. *ROBUST 94. Sborník prací zimní školy JČMF*, 1994: s. p. 32–43. 48
- [58] Jirik, M.; Kunes, J.; Zelezny, M.: Structure of organic compounds semantic quantitative evaluation of micro-CT data. *Pattern Recognition and Image Analysis*, ročník 26, č. 1, 2016: s. 144–149, ISSN 1054-6618, doi:10.1134/S1054661816010119. 86
- [59] Jirik, M.; Neduchal, P.: Experiments with automatic segmentation of liver parenchym using texture description. *Pattern Recognition and Image Analysis*, ročník 26, č. 3, 2016: s. 572–575, ISSN 15556212, doi:10.1134/S1054661816030081. 84
- [60] Jirik, M.; Ryba, T.; Zelezny, M.: Texture based segmentation using graph cut and Gabor filters. *Pattern Recognition and Image Analysis*, ročník 21, č. 2, 2011: s. 258–261, ISSN 1054-6618, doi:10.1134/S105466181102043X. 83



- [61] Jirik, M.; Tonar, Z.; Králíčková, A.; aj.: Stereological quantification of microvessels using semiautomated evaluation of X-ray microtomography of hepatic vascular corrosion casts. *International Journal of Computer Assisted Radiology and Surgery*, ročník 11, č. 10, 2016: s. 1803–1819, ISSN 1861-6429, doi: 10.1007/s11548-016-1378-3. 93, 103, 125
- [62] Jirik, M.; Zelezny, M.: Image segmentation in medical imaging via graph-cuts. *11th International Conference on Pattern Recognition and Image Analysis: New Information Technologies (PRIA-11-2013). Samara, Conference Proceedings*, 2013. 124, 130
- [63] Jirsová, Z.: Materiály k předmětu Praktická mikroskopie. 2014. xii, 15
- [64] Jonášová, A.; Rohan, E.; Lukeš, V.; aj.: Complex Hierarchical Modeling of the Dynamic Perfusion Test: Application to Liver. *wccm-eccm-ecfd2014.org*, , č. Wccm Xi, 2014: s. 1–12. 93
- [65] Kang, S. M.; Wan, J. W. L.: A multiscale graph cut approach to bright-field multiple cell image segmentation using a Bhattacharyya measure. ročník 8669, 2013: str. 86693S, ISSN 16057422, doi:10.1117/12.2007002. 65, 78, 80
- [66] Kaplan, S.; Odaci, E.; Canan, S.; aj.: The disector counting technique. *NeuroQuantology*, ročník 10, č. 1, 2012: s. 44–53, ISSN 13035150, doi:10.14704/nq.2012.10.1.425. 99, 100
- [67] Kass, M.; Witkin, A.; Terzopoulos, D.: Snakes: Active Contour Models. *International journal of computer vision*, ročník 1, č. 4, 1988: s. 321–331, ISSN 0920-5691, doi:10.1007/BF00133570. 61
- [68] Kubínová, L.; Janáček, J.: Estimating surface area by the isotropic fakir method from thick slices cut in an arbitrary direction. *Journal of Microscopy*, ročník 191, č. 2, 1998: s. 201–211, ISSN 00222720, doi:10.1046/j.1365-2818.1998.00356.x. xiv, 102, 103
- [69] Kutay, M.: Modeling moisture transport in asphalt pavements. *Zhurnal Eksperimental'noi i Teoreticheskoi Fiziki*, 2005. 102
- [70] Lam, N.-N.; Qiu, H. L.; Quattrochi, D. A.; aj.: An Evaluation of Fractal Methods for Characterizing Image Complexity. *Cartography and Geographic Information Science*, ročník 29, 2002: s. 25–35. 49
- [71] Laws, K. I.: *Textured Image Segmentation*. Dizertační práce, 1980. 50
- [72] Lazebnik, S.; Schmid, C.; Ponce, J.: A sparse texture representation using local affine regions. *IEEE transactions on pattern analysis and machine intelligence*, ročník 27, č. 8, aug 2005: s. 1265–78, ISSN 0162-8828, doi:10.1109/TPAMI.2005.151. 58

- [73] Lempitsky, V.; Zisserman, A.: Learning To Count Objects in Images. In *Advances in Neural Information Processing Systems*, 2010. 4
- [74] Lévi, P.: A special problem of brownian motion, and a general theory of gaussian random functions. *Third Berkeley Symposium Mathematical Statistics and Probability*, ročník vol 2, 1956: s. 133–175. 48
- [75] Liška, V.; Baxa, J.; Beneš, J.; aj.: *Experimental surgery*. Pilsen: NAVA, s. r. o., první vydání, 2016, ISBN 978-80-7211-490-0, 541 s. 130
- [76] Lowekamp, B. C.; Chen, D. T.; Ibáñez, L.; aj.: The Design of SimpleITK. *Frontiers in neuroinformatics*, ročník 7, č. December, jan 2013: str. 45, ISSN 1662-5196, doi: 10.3389/fninf.2013.00045. 86
- [77] Luis, A.; Luis, B.; Pablo, M.-N.; aj.: A Real Time Morphological Snakes Algorithm. *Image Processing On Line*, ročník 2, č. 1, 2012: s. 1–7, doi:10.5201/ipol.2012.abmh-rtmsa. 84
- [78] Lukeš, V.; Jiřík, M.; Jonášová, A.; aj.: Numerical simulation of liver perfusion: from CT scans to FE model. In *7th European Conference on Python in Science (EuroSciPy 2014)*, Euroscipy, Cambridge, UK, dec 2014, s. 79–84, 1412.6412. xiv, 93, 103, 131
- [79] Mäenpää, T.: The Local Binary Pattern Approach to Texture Analysis - Extensions and Applications. Infotech Oulu, 2003. 39
- [80] Mäenpää, T.; Ojala, T.; Pietikäinen, M.; aj.: Robust texture classification by subsets of Local Binary Patterns. *Proc. 15th International Conference on Pattern Recognition, Barcelona, Spain, 3:947 - 950.*, 2000. 41
- [81] Marquez-Neila, P.; Baumela, L.; Alvarez, L.: A morphological approach to curvature-based evolution of curves and surfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 36, č. 1, 2014: s. 2–17, ISSN 01628828, doi:10.1109/TPAMI.2013.106. 84
- [82] Mescher, A.: *Junqueira's Basic Histology: Text and Atlas*. McGraw Hill Professional, 2009, ISBN 9780071630207, 480 s. xii, 15
- [83] Miroslav Jiřík: skelet3d. 2014. 87
- [84] Movellan, J. R.: Tutorial on Gabor Filters. *Tutorial paper <http://mplab.ucsd.edu/tutorials/pdfs/gabor.pdf>*. 57
- [85] Nagel, H. D.: Multislice CT Technology. *Clinical Science CT*, ročník d, 2004: s. 2–7. 20
- [86] Nekula, J.; Heřman, M.; Vomáčka, J.; aj.: *Radiologie*. Univerzita Palackého, 2005, ISBN 9788024410111. 3, 9, 11, 19, 20, 22, 23, 25, 26, 27

- [87] Ojala, T.: A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, ročník 29, č. 1, 1996: s. 51–59. 38, 39, 58
- [88] Ojala, T.; Mäenpää, T.; Pietikäinen, M.; aj.: Outex - New framework for empirical evaluation of texture analysis algorithms. 2002. 58
- [89] Ojala, T.; Pietikäinen, M.; Mäenpää, T.: Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 24, č. 7, 2002: s. 971–987. 40
- [90] Otsu, N.: A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, ročník 9, č. 1, jan 1979: s. 62–66. 58
- [91] Paoluzzi, A.; Dicarolo, A.; Furiani, F.; aj.: CAD models from medical images using LAR. *Computer-Aided Design and Applications*, ročník 13, 2015: s. 1–19. 89
- [92] Paoluzzi, A.; Dicarolo, A.; Furiani, F.; aj.: CAD models from medical images using LAR. *Computer-Aided Design*, ročník 13, č. 6, 2016, ISSN 0010-4485, doi:10.1080/16864360.2016.1168216. 103, 130
- [93] Pedregosa, F.; Varoquaux, G.; Gramfort, A.; aj.: Scikit-learn: Machine Learning in {P}ython. *Journal of Machine Learning Research*, ročník 12, 2011: s. 2825–2830. 75
- [94] Pentland, A. P.: Fractal-Based Description of Natural Scenes. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, ročník PAMI-6, č. 6, 1984: s. 661–674, ISSN 0162-8828, doi:10.1109/TPAMI.1984.4767591. 49
- [95] Plachetzki, D. C.; Degnan, B. M.; Oakley, T. H.: The Origins of Novel Protein Interactions during Animal Opsin Evolution. *PLoS ONE*, ročník 2, č. 10, oct 2007: str. e1054. 4
- [96] Prasad, V. S. N.; Domke, J.: Gabor Filter Visualization. Technická zpráva, University of Maryland, 2005. 56
- [97] Prchal, J.; Šimák, B.: *Digitální zpracování signálů v telekomunikacích*. České vysoké učení technické, 2000. 53
- [98] Quinlan, J. R.: Induction of decision trees. *Machine learning*, ročník 1, č. 1, 1986: s. 81–106, ISSN 0885-6125, 1573-0565, doi:10.1023/A:1022643204877. 75
- [99] Rao, C. R.: The Utilization of Multiple Measurements in Problems of Biological Classification. *Journal of the Royal Statistical Society. Series B (Methodological)*, ročník 10, č. 2, 1948: s. 159–203. 75

- 
- [100] Rohan, E.; Lukeš, V.; Jonášová, A.; aj.: Towards Microstructure Based Tissue Perfusion Reconstruction from CT Using Multiscale Modeling. *Blucher Mechanical Engineering Proceedings*, ročník 1, č. May, 2014. 93
- [101] Röntgen, W. C.: Ueber eine neue Art von Strahlen. *Ann. Phys. Chem.*, ročník 64, č. 1, 1898: s. 1–37. 19
- [102] Ruberto, C. D.; Vitulano, S.; Rodriguez, G.: Image Segmentation by Texture Analysis. *Image Analysis and Processing, International Conference on Image Analysis and Processing*, ročník 0, 1999: str. 376, doi:<http://doi.ieeecomputersociety.org/10.1109/ICIAP.1999.797624>. 29
- [103] Ryba, T.; Jiřík, M.: Segmentace obrazu v lékařské diagnostice. In *Diagnostika, léčba a prevence závažných civilizačních onemocnění*, Plzeň: Euroverlag, 2010, ISBN 978-80-7177-034-3, str. 82. 124
- [104] Schoenberg, I. J.: SPLINE FUNCTIONS AND THE PROBLEM OF GRADUATION. *Proceedings of the National Academy of Sciences*, ročník 52, č. 4, oct 1964: s. 947–950, ISSN 0027-8424, doi:10.1073/pnas.52.4.947. 101
- [105] Sezgin, M.; Sankur, B.: Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, ročník 13, č. 1, 2004: s. 146–168, doi:10.1117/1.1631315. 58
- [106] Shapiro, L. G.; Stockman, G. C.: *Computer vision*. Prentice Hall, 2001. 61
- [107] Sharma, M.; Singh, S.: Evaluation Of Texture Methods For Image Analysis. In *Proceedings of the 7th Australian and New Zeland Intelligent Information System Conference*, ARCME, 2000, s. 117–121. 57
- [108] Sheng, Y.; Duvernoy, J.: Circular-Fourier-radial-Mellin transform descriptors for pattern recognition. *J. Opt. Soc. Am. A*, ročník 3, č. 6, jun 1986: s. 885–888, doi:10.1364/JOSAA.3.000885. 38
- [109] Siegel, R.; Desantis, C.; Jemal, A.: Colorectal cancer statistics, 2014. *CA: a cancer journal for clinicians*, ročník 64, č. 2, 2014: s. 104–17, ISSN 1542-4863, doi:10.3322/caac.21220. 5
- [110] Smola, A. J.; Schölkopf, B.: A tutorial on support vector regression. *Statistics and Computing*, ročník 14, 2004: s. 199–222, ISSN 0960-3174, doi:10.1023/B:STCO.0000035301.49549.88. 75
- [111] Soler, L.: 3D-IRCADB-01 (<http://www.ircad.fr/research/3d-ircadb-01/>). 104
- [112] Sonka, M.; Hlavac, V.; Boyle, R.: *Image Processing, Analysis, and Machine Vision Second Edition*. Thomson-Engineering, 2014, ISBN 978-1133593607. 28, 45, 47, 52, 59, 61, 62, 67

- [113] Sterio, D. C.: The unbiased estimation of number and sizes of arbitrary particles using the disector. *Journal of microscopy*, ročník 134, č. 2, 1984: s. 127–136. 99
- [114] Strong, R. W.; Lynch, S. V.; Ong, T. H.; aj.: Successful liver transplantation from a living donor to her son. *The New England Journal of Medicine*, ročník 322, č. 21, 1990: s. 1505–1507. 16, 17
- [115] Svojtka; Vašut: *Atlas anatomie*. Praha, 1996, ISBN 80-7180-092-9. xii, 10, 11, 13
- [116] Theodoridis, S.; Koutroumbas, K.: *Pattern Recognition, Third Edition*. Academic Press, feb 2006. 30, 31, 47, 48, 54, 75
- [117] Tin Kam Ho: Random decision forests. *Proceedings of 3rd International Conference on Document Analysis and Recognition*, ročník 1, 1995: s. 278–282, ISSN 0818671289, doi:10.1109/ICDAR.1995.598994. 75
- [118] Tomita, F.; Tsuji, S.: *Computer Analysis of Visual Textures*. Norwell, MA, USA: Kluwer Academic Publishers, 1990. 43, 51
- [119] Tonar, Z.: Atlas kvantitativní histologie. *lfp.cuni.cz*, 2008. 99
- [120] Tonar, Z.; Eberlová, L.; Polívka, J.; aj.: Stereological methods for quantitative assessment of hepatic microcirculation. 2012: s. 737–748. 86
- [121] Trojan, S.; kolektiv, A.: *Lékařská fyziologie*. Grada Publishing, 2003, ISBN 8024705125, 772 s. 12
- [122] Tuceryan, M.; Jain, A. K.: Texture Segmentation Using Voronoi Polygons. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 12, 1990: s. 211–216, ISSN 0162-8828, doi:http://doi.ieeecomputersociety.org/10.1109/34.44407. 43, 46
- [123] Tuceryan, M.; Jain, A. K.: Texture Analysis. In *The Handbook of Pattern Recognition and Computer Vision (2nd Edition)*, 1998. 29
- [124] Turner, M. R.: Texture discrimination by Gabor functions. *Biol. Cybern.*, ročník 55, 1986: s. 71–82. 53
- [125] Tyleček, R.: *Probabilistic Models for Symmetric Object Detection in Images*. Dizertační práce, Czech Technical University in Prague, 2015. 70
- [126] Ulzheimer, S.; Flohr, T.: Multislice CT : Current Technology and Future Developments. *Multislice CT*, 2009: s. 3 – 23, ISSN 0942-5373, doi:10.1007/978-3-540-33125-4\_1. 20
- [127] Urata, K.; Kawasaki, S.; Matsunami, H.; aj.: Calculation of child and adult standard liver volume for liver transplantation. *Hepatology*, ročník 21, č. 5, may 1995: s. 1317–1321, ISSN 02709139, doi:10.1002/hep.1840210515. 13, 67

- 
- [128] Válek, V.; Žižka, J.: *Modern\{i} diagnostické metody: Magnetická rezonance III.d\{i}l.* Institut pro dalš\{i} vzděláván\{i} pracovník\{o}u\{v}e zdravotnictv\{i} Brno, 1996, ISBN 57-866-96, 45 s. 25, 26, 27
- [129] Vankan, W.; Huyghe, J.; Janssen, J.; aj.: Finite element analysis of blood flow through biological tissue. *International Journal of Engineering Science*, ročník 35, č. 4, 1997: s. 375–385, ISSN 00207225, doi:10.1016/S0020-7225(96)00108-5. xiv, 92
- [130] Weinreb, J.; Kumari, S.; Phillips, G.; aj.: Portal Vein by Real-Time Measurements Sonography. *American journal of Roentgenology*, ročník 139, 1982: s. 497–499. 7
- [131] Woods, J.: Two-dimensional discrete Markovian fields. *IEEE Transactions on Information Theory*, ročník 18, 1972: s. 232–240, doi:10.1109/TIT.1972.1054786. 48
- [132] Xie, J.; Jiang, Y.; Tsui: Segmentation of kidney from ultrasound images based on texture and shape priors. *IEEE Transactions on Medical Imaging*, ročník 24, č. 1, 2005: s. 45–57. 57
- [133] Zhang, H.: The Optimality of Naive Bayes. *Proceedings of the Seventeenth International Florida Artificial Intelligence Research Society Conference FLAIRS 2004*, ročník 1, č. 2, 2004: s. 1 – 6, ISSN 01678655, doi:10.1016/j.patrec.2005.12.001. 75
- [134] Zuna, I.; Poušek, L.: *Úvod do zobrazovacích metod v lékařské diagnostice#I#*. Nakladatelství ČVUT, 2007. 23
- [135] Zwillinger, D.; Kokoska, S.: *CRC standard probability and statistics tables and formulae*. 1999, ISBN 9781584880592, 568 s., doi:10.1198/tech.2001.s620. 121

10

Přílohy

# Seznam publikovaných prací

- [1] M. Jirik, T. Ryba, and M. Zelezny. Texture based segmentation using graph cut and Gabor filters. *Pattern Recognition and Image Analysis*, 21(2):258–261, 2011. 84
- [2] Miroslav Jirik, Jiri Kunes, and Milos Zelezny. Structure of organic compounds semantic quantitative evaluation of micro-CT data. *Pattern Recognition and Image Analysis*, 26(1):144–149, 2016.
- [3] Miroslav Jirik and Petr Neduchal. Experiments with automatic segmentation of liver parenchym using texture description. *Pattern Recognition and Image Analysis*, 26(3):572–575, 2016.
- [4] Miroslav Jirik, Zbyněk Tonar, Anna Králíčková, Lada Eberlová, Hynek Mírka, Petra Kochová, Tomáš Gregor, Petr Hošek, Miroslava Svobodová, Eduard Rohan, Milena Králíčková, and Václav Liška. Stereological quantification of microvessels using semiautomated evaluation of X-ray microtomography of hepatic vascular corrosion casts. *International Journal of Computer Assisted Radiology and Surgery*, 11(10):1803–1819, 2016. 93, 103, 125
- [5] M Jiřík, T Ryba, M Svobodová, H Mírka, and V Liška. LISA-Liver Surgery Analyser Software Development. In *11th World Congress on Computational Mechanics (WCCM XI), 5th European Conference on Computational Mechanics (ECCM V), 6th European Conference on Computational Fluid Dynamics (ECFD VI)*, 2014.
- [6] M. Jiřík, T. Ryba, and M. Železný. Gabor filter and graph cut based texture analysis. *Pattern Recognition and Image Analysis*, 22(1):215–220, mar 2012.
- [7] Václav Liška, Jan Baxa, Jan Beneš, Jan Brůha, Jiří Ferda, Petr Hošek, Magdaléna Jansová, Miroslav Jiřík, Alena Jonášová, Milena Králíčková, Jana Křečková, Jiří Křen, Libor Lobovský, Vladimír Lukeš, Hynek Mírka, Richard Pálek, Martin Pešta, Pavel Pitule, Eduard Rohan, Josef Rosenberg, Martin Skála, Tomáš Skalický, Milan Štengl, Miroslava Svobodová, Zbyněk Tonar, Vladislav Třeška, Radek Tupý, Jan Vimmr, and Ondřej Vyčítal. *Experimental surgery*. NAVA, s. r. o., Pilsen, 1 edition, 2016. 130
- [8] Vladimír Lukeš, Miroslav Jiřík, Alena Jonášová, Eduard Rohan, Ondřej Bublík, and Robert Cimrman. Numerical simulation of liver perfusion: from CT scans to



- FE model. In *7th European Conference on Python in Science (EuroSciPy 2014)*, number Euroscipy, pages 79–84, Cambridge, UK, dec 2014. xiv, 93, 103, 131
- [9] Alberto Paoluzzi, Antonio Dicarolo, Francesco Furiani, and Miroslav Jirik. CAD models from medical images using LAR. *Computer-Aided Design*, 13(6), 2016.
- [10] I Pirner, M Jiřík, and M Železný. Segmentation of CT arteriography based on combination of segmentation methods. *Pattern Recognition and Image Analysis*, 21(3):553–555, 2011.
- [11] T Ryba, M Jirik, and M Zelezny. An automatic liver segmentation algorithm based on grow cut and level sets. *Pattern recognition and image analysis*, 23(4):502–507, 2013.
- [12] Miroslava Svobodová, Miroslav Jiřík, Ing. Petr Včelák, Vladimír Lukeš, Tomáš Ryba, Petr Hošek, Kristýna Bajcurová, Jaroslav Ludvík, Hynek Mirka, Zbyněk Tonar, Vladislav Třeška, and Václav Liška. Software LISA - virtuální resekce jater pro urychlení a usnadnění předoperačního plánování. *Rozhledy v chirurgii*, 94(11):485–490, 2015.

## Seznam ostatních prací

- [1] Miroslav Jirik. Měření objemu ve snímcích z výpočetní tomografie. In *Studentská vědecká konference 2013*, 2013.
- [2] Miroslav Jirik. Praktické aspekty vývoje softwaru pro klinickou praxi. In *Studentská vědecká konference 2014*, 2014.
- [3] Miroslav Jirik and M Zelezny. Image segmentation in medical imaging via graph-cuts. *11th International Conference on Pattern Recognition and Image Analysis: New Information Technologies (PRIA-11-2013). Samara, Conference Proceedings*, 2013. 124, 130
- [4] M Jiřík and T Ryba. Interaktivní segmentace pomocí metody Graph-Cut v prostředí Matlab. In *SVK 2010 - magisterské a doktorské studijní programy, sborník rozšířených abstraktů*, pages 23–24. Západočeská univerzita v Plzni, 2010.
- [5] T Ryba, M Jirik, and H Mirka. Analýza jaterního parenchymu metodami zpracování obrazu. In *Experimentální výzkum v medicíně a jeho klinická aplikace*, page 23. Euroverlag, 2011.
- [6] T Ryba, M Jirik, and M Železný. An Automatic Liver Segmentation Algorithm. In *8th Open German-Russian Workshop: Pattern Recognition and Image Understanding, proceeding of extended abstracts*, pages 246–249, 2011.
- [7] T Ryba and M Jiřík. Segmentace obrazu v lékařské diagnostice. In *Diagnostika, léčba a prevence závažných civilizačních onemocnění*, page 82, Plzeň, 2010. Euroverlag. 124
- [8] Miloš Železný, Zdeněk Krňoul, Miroslav Jiřík, Tomáš Ryba, Ivan Pirner, and Petr Zimmermann. Simple Gesture Based Medical Data Interface. In *8th Open German-Russian Workshop*. Russian Academy of Sciences, Mathematical Sciences Branch of the Russian Academy of Sciences, National Committee of the RAS for Pattern Recognition and Image Analysis, 2011.

**Tabulka 10.1:** Měření histologických parametrů prostřednictvím automatické a manuální metody s poloměrem uzlu 0,012 mm

	Vv a	Vv m	Sv a	Sv m	Lv a	Lv m	Nv a	Nv m	Tort a	Tort m
0	0.125232	0.122981	23.153169	20.787224	203.799572	180.069769	865.796874	621.110421	1.215660	1.068190
1	0.195767	0.152382	21.927144	20.228426	203.610658	179.525738	1016.753713	753.024160	1.257121	1.265813
2	0.116151	0.277353	20.462730	28.988519	147.751934	191.649031	454.264658	826.867428	1.190817	1.260868
3	0.080280	0.258730	18.436118	32.996559	129.957819	224.179018	366.816955	1342.031590	1.193031	1.094576
4	0.027125	0.031347	7.775427	8.440914	107.564340	116.030745	241.097490	545.894936	1.361036	1.148312
5	0.038888	0.025861	8.381397	7.311496	80.431939	77.111996	140.003810	273.447468	1.173067	1.227213
6	0.024743	0.025339	5.294683	5.112103	82.647039	61.744621	127.367100	261.063492	1.402264	1.130307
7	0.022727	0.036310	6.217143	4.933774	70.030716	80.577478	127.367100	310.599395	1.231252	1.139240
8	0.023660	0.025078	6.350954	4.814888	123.527871	100.472211	392.738010	521.126984	1.463323	1.161483
9	0.060630	0.056686	9.937015	8.262585	101.342615	81.665039	253.734200	360.135299	1.304152	1.247247
10	0.017157	0.013061	3.904862	3.209925	45.095793	46.213109	140.003810	236.295540	1.150039	1.150109
11	0.030788	0.030824	6.922449	3.863799	47.086101	50.872233	76.820260	174.375661	1.195888	1.131207
12	0.008945	0.007837	2.725087	1.248304	28.227967	27.581640	51.546840	112.455782	1.303537	1.146037
13	0.001759	0.001567	0.770879	0.891646	12.216039	13.113342	26.273420	38.151927	1.119242	1.213208

**Tabulka 10.2:** Měření histologických parametrů prostřednictvím automatické a manuální metody s poloměrem uzlu 0,015 mm

	Vv a	Vv m	Sv a	Sv m	Lv a	Lv m	Nv a	Nv m	Tort a	Tort m
0	0.027125	0.031347	7.775427	8.440914	123.781848	116.030745	519.105111	545.894936	1.206062	1.148312
1	0.038888	0.025861	8.381397	7.311496	88.519983	77.111996	241.097490	273.447468	1.158299	1.227213
2	0.024743	0.025339	5.294683	5.112103	74.718163	61.744621	266.370910	261.063492	1.177075	1.130307
3	0.022727	0.036310	6.217143	4.933774	88.584745	80.577478	279.007620	310.599395	1.205489	1.139240
4	0.023660	0.025078	6.350954	4.814888	123.955560	100.472211	645.472211	521.126984	1.294957	1.161483
5	0.060630	0.056686	9.937015	8.262585	96.190096	81.665039	380.101300	360.135299	1.131218	1.247247
6	0.017157	0.013061	3.904862	3.209925	57.105916	46.213109	304.281040	236.295540	1.161900	1.150109
7	0.030788	0.030824	6.922449	3.863799	58.284210	50.872233	190.550650	174.375661	1.196194	1.131207
8	0.008945	0.007837	2.725087	1.248304	51.807107	27.581640	215.824070	112.455782	1.281565	1.146037
9	0.001759	0.001567	0.770879	0.891646	12.800060	13.113342	38.910130	38.151927	1.127314	1.213208
10	0.125232	0.122981	23.153169	20.787224	201.355043	180.069769	762.632593	621.110421	1.238378	1.068190
11	0.195767	0.152382	21.927144	20.228426	205.086353	179.525738	892.351059	753.024160	1.296181	1.265813
12	0.116151	0.277353	20.462730	28.988519	143.323419	191.649031	392.025332	826.867428	1.197994	1.260868
13	0.080280	0.258730	18.436118	32.996559	126.001714	224.179018	307.091738	1342.031590	1.209926	1.094576

**Tabulka 10.3:** Měření histologických parametrů prostřednictvím automatické a manuální metody s poloměrem uzlu 0,018 mm

	Vv a	Vv m	Sv a	Sv m	Lv a	Lv m	Nv a	Nv m	Tort a	Tort m
0	0.027125	0.031347	7.775427	8.440914	121.947141	116.030745	405.374720	545.894936	1.287437	1.148312
1	0.038888	0.025861	8.381397	7.311496	86.560933	77.111996	215.824070	273.447468	1.168028	1.227213
2	0.024743	0.025339	5.294683	5.112103	70.482895	61.744621	215.824070	261.063492	1.124313	1.130307
3	0.022727	0.036310	6.217143	4.933774	82.800322	80.577478	203.187360	310.599395	1.239344	1.139240
4	0.023660	0.025078	6.350954	4.814888	122.069648	100.472211	531.741821	521.126984	1.315877	1.161483
5	0.060630	0.056686	9.937015	8.262585	98.954358	81.665039	316.917750	360.135299	1.201442	1.247247
6	0.017157	0.013061	3.904862	3.209925	53.474653	46.213109	241.097490	236.295540	1.163899	1.150109
7	0.030788	0.030824	6.922449	3.863799	56.401847	50.872233	165.277230	174.375661	1.166919	1.131207
8	0.008945	0.007837	2.725087	1.248304	46.505498	27.581640	152.640520	112.455782	1.467849	1.146037
9	0.001759	0.001567	0.770879	0.891646	12.496265	13.113342	38.910130	38.151927	1.085424	1.213208
10	0.125232	0.122981	23.153169	20.787224	194.714065	180.069769	670.931010	621.110421	1.266083	1.068190
11	0.195767	0.152382	21.927144	20.228426	202.082677	179.525738	773.987368	753.024160	1.314159	1.265813
12	0.116151	0.277353	20.462730	28.988519	137.722590	191.649031	343.316294	826.867428	1.209532	1.260868
13	0.080280	0.258730	18.436118	32.996559	120.301947	224.179018	259.809274	1342.031590	1.224765	1.094576