


**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH  
TECHNOLOGIÍ**

**ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION  
DEPARTMENT OF BIOMEDICAL ENGINEERING

## **TVAROVÁ KLASIFIKACE PRO DETEKCI CHYBNĚ SEGMENTOVANÝCH KOSTÍ V CT DATECH**

CONTOUR SHAPE CLASSIFICATION FOR DETECTION OF MIS-SEGMENTED BONES IN CT  
DATA

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. TOMÁŠ JANOVIČ**

**VEDOUCÍ PRÁCE**

SUPERVISOR

**Ing. PETR WALEK**

BRNO 2014



VYSOKÉ UČENÍ  
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

Ústav biomedicínského inženýrství

# Diplomová práce

magisterský navazující studijní obor  
**Biomedicínské inženýrství a bioinformatika**

**Student:** Bc. Tomáš Janovič

**ID:** 125031

**Ročník:** 2

**Akademický rok:** 2013/2014

## NÁZEV TÉMATU:

**Tvarová klasifikace pro detekci chybně segmentovaných kostí v CT datech**

## POKYNY PRO VYPRACOVÁNÍ:

1) Provedte literární rešerši publikovaných metod a algoritmů pro segmentaci kostních struktur v objemových datech získaných pomocí rentgenové výpočetní tomografie. 2) Provedte segmentaci kortikálních částí kostí metodou prostého prahování s globálním prahem. Práh určete optimalizovaným proložením histogramu Gaussovými křivkami. 3) Prostudujte a popište možnosti, kterými lze kvantitativně popisovat tvary objektů v obrazu. 4) Vyberte a v prostředí MATLAB realizujte vhodné tvarové deskriptory. 5) Na základě vybraných tvarových deskriptorů provedte detekci úseků počátečních a koncových bodů nedostatečně segmentovaných (přerušených) kostních struktur. 6) Provedte diskuzi a zhodnocení dosažených výsledků.

## DOPORUČENÁ LITERATURA:

- [1] JAN, J. Medical Image Processing, Reconstruction and Restoration: Concepts and Methods. Boca Raton: CRC Press, 2005, ISBN 0-8247-5849-8.
- [2] WANG, L. I., GREENSPAN, M. a ELLIS R. Validation of bone segmentation and improved 3-D registration using contour coherency in CT data. IEEE transactions on medical imaging. 2006, roč. 25, č. 3, s. 324–34.

**Termín zadání:** 10.2.2014

**Termín odevzdání:** 23.5.2014

**Vedoucí práce:** Ing. Petr Walek

**Konzultanti diplomové práce:**

**prof. Ing. Ivo Provazník, Ph.D.**

*Předseda oborové rady*

## UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## ABSTRAKT

Práce pojednává o možnostech využití tvarové klasifikace pro detekci chybně segmentovaných (přerušených) kostí v datech výpočetní tomografie (CT). Je provedena rešerše publikovaných metod a algoritmů zabývajících se segmentací kostních struktur v CT datech. Následně je implementována segmentace kortikálních částí kostí metodou prostého prahování s globálním prahem. Práh je určen optimalizovaným proložením histogramu vybraným typem pravděpodobnostního rozdělení. Dále jsou popsány deskriptory, kterými lze kvantitativně popisovat tvary objektů v obrazu. Následně je implementována extrakce kontur a je aplikován vyhovující tvarový deskriptor - kumulativní úhlová funkce. Finálně jsou pomocí spojitě vlnkové transformace detekovány body, které mohou potenciálně indikovat chybně segmentované kosti. Zmíněná technika je testována na reálných CT datech.

## KLÍČOVÁ SLOVA

výpočetní tomografie, segmentace kostí, prahování, tvarová klasifikace, kumulativní úhlová funkce

## ABSTRACT

The thesis discusses the possibilities of using contour shape classification for detection of mis-segmented bones in computed tomography (CT) data. In the first part there are presented published methods and algorithms which deal with the segmentation of bone structures in CT data. Then segmentation of cortical bones is implemented by a simple thresholding with global threshold. The threshold is determined by the optimized fitting of a selected type probability distribution to the histogram. Subsequently, the thesis describes some important shape descriptors that can quantitatively describe the shapes of objects in the image. Further, the contour extraction is implemented and a suitable shape descriptor, cumulative angular function, is applied. Finally, the points which can potentially indicate mis-segmented bones are detected by using continuous wavelet transform. The proposed technique is tested on the real CT data.

## KEYWORDS

computed tomography, bone segmentation, thresholding, cumulative angular function, wavelet transform

JANOVIČ, Tomáš *Tvarová klasifikace pro detekci chybně segmentovaných kostí v CT datech*: diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2013. 67 s. Vedoucí práce byl Ing. Petr Walek

## PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Tvarová klasifikace pro detekci chybně segmentovaných kostí v CT datech“ jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno .....

.....

(podpis autora)

## PODĚKOVÁNÍ

Velmi rád bych touto cestou poděkoval vedoucímu diplomové práce panu Ing. Petru Walkovi, jehož bezvadné vedení, mnoho přínosných návrhů, rad a v neposlední řadě také hodiny strávené kontrolou výsledné práce byly velmi přínosné, čehož si velmi vážím.

Brno .....

.....

(podpis autora)

# OBSAH

Úvod	9
<b>1 Medicínská Obrazová data</b>	<b>11</b>
1.1 Obrazová CT data . . . . .	11
1.2 DICOM standard . . . . .	13
<b>2 Publikované segmentační metody</b>	<b>14</b>
2.1 Kangova metoda . . . . .	14
2.2 Segmentace s využitím 3D adaptivního prahování . . . . .	17
<b>3 Implementace segmentace kortikálních částí kostí</b>	<b>20</b>
3.1 Zisk binární masky hlavy . . . . .	21
3.2 Proložení histogramu pravděpodobnostním rozdělením . . . . .	23
3.2.1 Normální (Gaussovo) rozdělení . . . . .	23
3.2.2 Pearsonovo rozdělení typu VII . . . . .	25
3.3 Prahování s globálním prahem . . . . .	26
<b>4 Tvarová klasifikace</b>	<b>29</b>
4.1 Globální reprezentace tvaru na základě kontur . . . . .	30
4.1.1 Jednoduché tvarové deskriptory . . . . .	30
4.1.2 Tvarové porovnávání založené na korespondenci . . . . .	30
4.1.3 Tvarové charakteristiky . . . . .	32
4.1.4 Fourierovy deskriptory . . . . .	33
4.1.5 Vlnkové deskriptory . . . . .	34
4.2 Strukturní reprezentace tvaru na základě kontur . . . . .	35
4.2.1 Řetězový kód . . . . .	35
4.2.2 Polygonální aproximace . . . . .	36
<b>5 Implementace vybraných tvarových deskriptorů</b>	<b>37</b>
5.1 Extrakce kontur . . . . .	37
5.2 Funkce vzdálenosti od těžiště . . . . .	38
5.3 Kumulativní úhlová funkce . . . . .	39
5.4 Funkce popisující směrnicí tečny . . . . .	40
5.5 Fourierovy deskriptory . . . . .	41
5.6 Vlnkové deskriptory . . . . .	41

<b>6</b>	<b>Detekce potenciálně chybně segmentovaných úseků</b>	<b>43</b>
6.1	Detekce bodů u kumulativní úhlové funkce . . . . .	45
6.2	Detekce bodů u funkce popisující směrnici tečny . . . . .	47
<b>7</b>	<b>Výsledky detekce a možnosti využití</b>	<b>49</b>
7.1	Výsledky detekce potenciálně chybně segmentovaných úseků . . . . .	49
7.2	Možnosti využití znalosti pozic detekovaných úseků . . . . .	53
7.2.1	Klasifikace trabekulárních částí kostí . . . . .	53
7.2.2	Možnosti doplnění přerušovaných kortikálních částí kostí . . . . .	55
<b>8</b>	<b>Závěr</b>	<b>58</b>
	<b>Literatura</b>	<b>60</b>
	<b>Seznam symbolů, veličin a zkratk</b>	<b>63</b>
	<b>Seznam příloh</b>	<b>64</b>
<b>A</b>	<b>Originální obrazová CT data</b>	<b>65</b>
<b>B</b>	<b>Výsledky detekce potenciálně chybně segmentovaných kostí</b>	<b>66</b>

# SEZNAM OBRÁZKŮ

1.1	Hounsfieldova stupnice CT hodnot . . . . .	12
2.1	Histogram CT čísel objemových dat . . . . .	15
2.2	Výsledek segmentace I. a II. kroku (koronální pohled) . . . . .	16
2.3	Segmentace endostu . . . . .	17
2.4	Ilustrace 2D segmentační procedury . . . . .	18
2.5	Výsledek 3D adaptivního prahování . . . . .	19
3.1	Vývojový diagram segmentace . . . . .	20
3.2	Vývojový diagram zisku binární masky hlavy . . . . .	21
3.3	Postup získání binární masky hlavy . . . . .	22
3.4	Histogram stupňů šedi objemových dat proložený Gaussovou funkcí . . . . .	24
3.5	Histogram stupňů šedi objemových dat proložený Pearsonovou funkcí . . . . .	26
3.6	Výsledek segmentace kortikálních částí kostí . . . . .	27
4.1	Možnosti reprezentace tvarů v obrazu . . . . .	29
4.2	Tvarové souvislosti . . . . .	31
5.1	Extrakce kontury . . . . .	37
5.2	Extrakce kontury . . . . .	38
5.3	Funkce vzdálenosti od těžiště . . . . .	39
5.4	Kumulativní úhlová funkce . . . . .	40
5.5	Funkce popisující směrnicí tečny . . . . .	40
5.6	Rekonstrukce funkce dle FDs . . . . .	41
5.7	Deskriptor založený na CWT . . . . .	42
6.1	Vývojový diagram detekce potenciálně chybně segmentovaných úseků . . . . .	43
6.2	Přerušení (rozpadnutí) kosti na malé části vlivem segmentace . . . . .	44
6.3	Ukázka vlivu členitosti kontury na rozptyl koeficientů CWT . . . . .	46
6.4	Detekce pozic potenciálně chybně segmentovaných úseků s využitím CWT . . . . .	47
6.5	Detekce pozic potenciálně chybně segmentovaných úseků u funkce popisující směrnicí tečny . . . . .	48
7.1	Detekce úseků chybně segmentované spánkové kosti . . . . .	50
7.2	Ukázka detekce úseků chybně segmentovaných nosních kůstek . . . . .	51
7.3	Ukázka situací kdy implementovaný algoritmus selhává . . . . .	52
7.4	Ukázka metody doplnění chybně segmentovaných úseků pro případ správně detekovaných bodů . . . . .	56
7.5	Ukázka metody doplnění chybně segmentovaných úseků pro případ falešně detekovaných bodů . . . . .	57
A.1	Originální snímky pro vizuální kontrolu správnosti výsledku . . . . .	65
B.1	Ukázka výsledků detekce potenciálně chybně segmentovaných kostí . . . . .	67



# ÚVOD

Hlavní náplní práce je aplikace tvarových deskriptorů pro detekci chybně segmentovaných dat získaných pomocí rentgenové výpočetní tomografie (CT). Úkolem je prostudovat publikované metody a algoritmy zabývající se segmentací kostních struktur v objemových CT datech. Provést segmentaci kortikálních částí kostí metodou prostého prahování s globálním prahem, stanoveným dle optimalizovaného proložení histogramu vhodným pravděpodobnostním rozdělením. Popsat možnosti, kterými lze kvantitativně popisovat tvary objektů v obrazu a zároveň aplikovat vhodné tvarové deskriptory pro následnou detekci nedostatečně segmentovaných (přerušených) kostních struktur.

Historicky položil základy výpočetní tomografie W. C. Röntgen, když roku 1895 objevil rentgenové (RTG) záření, což je forma elektromagnetického vlnění o velmi krátkých vlnových délkách (10 nm - 100 pm). V 70. letech 20. století G. N. Hounsfield zkonstruoval první tomograf využívající právě RTG záření k zisku jednotlivých projekcí pod různými úhly, na které byl následně aplikován matematický aparát A. M. Cormacka pro rekonstrukci výsledného obrazu (řezu) pozorovaného objektu. Za tento přínos získali oba vědci roku 1979 Nobelovu cenu za fyziologii a medicínu. [10] [23]

Dnes je CT nedílnou součástí téměř všech radiologických pracovišť využívajících moderní rekonstrukční tomografické zobrazovací metody. Využívá se např. při pozorování hlavy k odhalení nádorů, hemoragií, kalcifikací nebo kostních fraktur. Dále také pro detekci akutních a chronických změn v plicním parenchymu, neboť CT dosahuje vyšší prostorové rozlišení než konvenční RTG zobrazení, díky čemuž lze pozorovat i drobné změny (detaily) v tkáni. K diagnóze plicní embolie se používá tzv. CT plicní angiografie (CTPA), kdy za pomoci kontrastní látky jsou zobrazeny plicní artérie. CT také slouží pro diagnózu břišních onemocnění jako jsou např. zánět slinivky břišní, zánět slepého střeva, břišní aortální výduť, ledvinové kameny aj. Často se mimo jiné využívá k určení stádia rakoviny a sledování jejího průběhu. K zobrazení pánve jsou v praxi, pokud se nejedná o posouzení fraktur, upřednostňovanými metodami magnetická rezonance (MRI) a ultrazvuk. Velmi často je CT využíváno k vyhodnocování složitých fraktur končetin, zejména kloubů, kde především díky objemovému zobrazení lze oblast zájmu pozorovat ve více rovinách. S rozvojem moderních multidetektorových CT přístrojů se rozšířily možnosti diagnózy srdce, resp. koronárního systému, kdy lze sledovat za pomoci kontrastní látky dynamické plnění tepen a tím stanovit stupeň aterosklerotického poškození pro následné potvrzení, či vyloučení, ischemické choroby srdeční (ICHS).

Trend zvyšování počtu tomografických vyšetření a také zvyšování rozlišení získaných dat vede k rozvoji diagnostických procedur založených na vizuálním pozorování

každého 2D řezu. V případě efektivního zhodnocení velkého množství dat je nutno do procesu zařadit nástroje pro extrakci a měření objemové informace bez, nebo s minimálním zásahem operátora. Z tohoto důvodu jsou vyžadovány segmentační přístupy, kde pro analýzu 3D objemových dat existuje řada segmentačních metod a algoritmů používaných v medicíně.

Pojmem segmentace se myslí rozčlenění analyzovaného obrazu na oblasti, které mají úzkou souvislost s předměty či oblastmi reálného světa zachyceného na obrazu. Výsledkem jsou poté oblasti, které se vzájemně nepřekrývají (jsou disjunktí) a zároveň, aby jejich sjednocení pokrývalo celý obraz. Tyto oblasti sdílejí společné vlastnosti jako je např. hodnota stupně šedi, barva, textura, apod. [12]

Praktické uplatnění segmentace kostních struktur v objemových CT datech nalezneme např. při počítačově a roboticky asistované operaci, konstrukci implantátů, měření kostní denzity či tvorbě prostorového modelu pro následnou studii.

Práce je organizována následovně: v první části je věnován prostor pro popis medicínských, resp. objemových CT dat, poté je provedena rešerše publikovaných segmentačních metod kostních struktur a také popis vlastní implementace segmentace kortikálních částí kostí. Následně se práce zabývá možnostmi popisu a reprezentací tvarů objektů v obrazu spolu s aplikací vhodných tvarových deskriptorů pro detekci pozic nedostatečně segmentovaných kortikálních částí kostí. V další části je objasněn implementovaný algoritmus pro detekci potenciálních míst, kde došlo k přerušení segmentace kortikálních částí kostí. Na závěr jsou předloženy a diskutovány dosažené výsledky, spolu s možnostmi využití.

# 1 MEDICÍNSKÁ OBRAZOVÁ DATA

Obrazová data reprezentují distribuci fyzikální veličiny - primárního parametru (PP) v měřené scéně - primárním parametrickém poli (PPP). Dle žádané diagnostické potřeby umožňují různé modalities měřit odlišný PP. [5]

Obecně lze vícerozměrný spojitý signál definovat jako

$$f(\mathbf{x}), \quad (1.1)$$

kde složky vektoru  $\mathbf{x}$  mohou mít libovolný fyzikální význam. V praxi se nejčastěji setkáváme se statickým obrazem jako dvourozměrnou jasovou funkcí  $f(x, y)$ . U třírozměrných signálů se může jednat buď o vývoj dvourozměrné scény v čase  $f(x, y, t)$ , nebo o objemová (tomografická) data  $f(x, y, z)$ . Časově proměnná, objemová data  $f(x, y, z, t)$  představují v současné době vrchol mezi metodami lékařské zobrazovací techniky používaných např. při dynamickém vyšetření srdce, či plnění tepen kontrastní látkou. Vícerozměrné signály mohou být také vektorové, příkladem je barevný 2D obraz, kde jednotlivé složky jsou vyjádřeny vektorem hodnot reprezentujících jednotlivé barevné komponenty RGB. [11] [12]

Obdobně lze definovat dvourozměrný diskretní signál, který je obdržen navzorkováním spojitě verze s kroky  $\Delta x, \Delta y$ . Poté nese o signálu  $f(x, y)$  úplnou informaci matice vzorků

$$\bar{\mathbf{f}} = [f_{i,k}], \quad f_{i,k} = f(i\Delta x, j\Delta y), \quad (1.2)$$

kde  $f_{i,k}$  představuje jednotlivé diskretizované elementy - pixely. Tomografická data jsou diskretizována na objemové elementy scény nazývané voxely, které reprezentují hodnotu PP v pravidelné třírozměrné mřížce - matici. [5] [11] [12]

## 1.1 Obrazová CT data

Akvizicí objemových dat u CT dochází k prostorové diskretizaci scény na voxely, ve kterých je vyhodnocena hodnota PP, kterým je, stejně jako u projekčního RTG zobrazování, lineární součinitel zeslabení  $\mu$  [ $\text{cm}^{-1}$ ], resp. hmotnostní koeficient zeslabení  $\mu_m$  [ $\text{g}^{-1}\text{cm}^{-4}$ ]. Vlastní princip akvizice je založen na postupném měření útlumu úzce zkolimovaného paprsku RTG záření během rotačně - translačního pohybu soustavy rentgenka - detektor. Vždy během translačního pohybu je sejmuta jedna projekce scény, která je získána z jednotlivých měření celkového útlumu RTG záření ve sloupci tkáně definovaném tzv. paprskovým integrálem. Vyjádření intenzity RTG záření  $I$  v pozici  $y$  šířícího se vrstvou tloušťky  $D$  ve směru  $x$ , lze formulovat

$$I(y) = I_0(y) \exp \left( - \int_0^D \mu(x, y) dx \right). \quad (1.3)$$

Poté dle rovnice (1.3) jsou získána projekční data - paprskový integrál

$$p(y) = -\ln \left[ \frac{I(y)}{I_0(y)} \right] = \int_0^D \mu(x, y) dx, \quad (1.4)$$

který lze v diskrétní formě vyjádřit ve tvaru

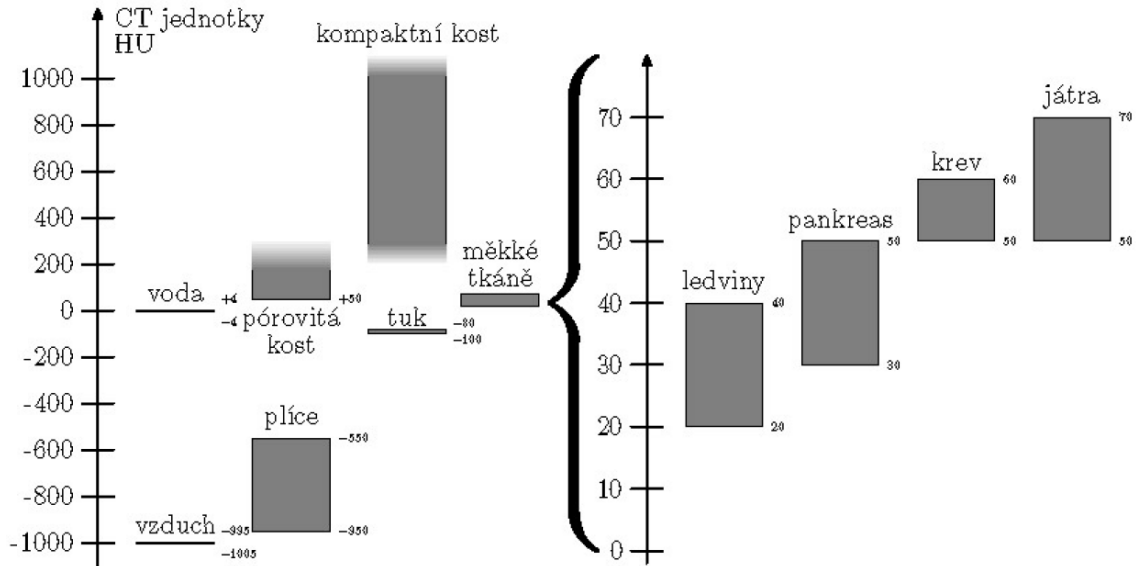
$$p(y) = \sum_{i=1}^m \mu(x, y), \quad i = 1, 2, \dots, m. \quad (1.5)$$

Po sejmutí souboru projekcí téže scény v kompletních 180° nebo 360° následuje rekonstrukce obrazu z projekcí pomocí různých rekonstrukčních metod (podrobněji v [5], [12]). [5]

Pro kvantitativní vyjádření obrazové modulace PP byla zavedena relativní stupnice tzv. CT čísel vyjadřovaná pomocí bezrozměrné Hounsfieldovy jednotky HU (*angl.* Hounsfield Unit)

$$CT_{\text{číslo}} = K \frac{(\mu_{\text{tkáňe}} - \mu_{\text{vody}})}{\mu_{\text{vody}}}, \quad [\text{HU}], \quad (1.6)$$

kde  $\mu_{\text{vody}} = 0,19 \text{ cm}^{-1}$  je relativní hodnota definována pro energii  $E = 73 \text{ keV}$  monoenergetického záření.  $K$  je kontrastní/měřítkový faktor, typicky roven 1000, při kterém je přesnost měření 0,1%/CT číslo. [5]



Obr. 1.1: Hounsfieldova stupnice CT hodnot. [5]

Dle obr. 1.1 lze vidět, že Hounsfieldova stupnice má dva pevné body nezávislé na energii RTG záření: 0 HU náležící útlumu vody a -1000 HU pro útlum vzduchu.

U kostní tkáňe jsou obvyklé hodnoty kolem +1000 HU. Je třeba podotknout, že horní mez stupnice není pevně stanovena, ale v praxi je většinou používán dynamický rozsah od -1024 až +3071 HU, kde každý voxel je kvantován 12-ti bity (4096 diskretních hodnot). [5] [12]

## 1.2 DICOM standard

Obrovský vzestup zavádění digitálních diagnostických zobrazovacích systémů v lékařských pracovištích spolu s rozvojem výpočetní techniky vyžadoval specifický standard pro přenos, vizualizaci, tisk a zálohování medicínských obrazových dat spolu s přidruženými informacemi. Na tento popud American College of Radiology (ACR) a National Electrical Manufacturers Association (NEMA) vytvořili a v roce 1993 publikovali standard DICOM (Digital Imaging and Communications in Medicine), který podporuje výše uvedené požadavky, je aplikovatelný na off-line médiích a zároveň v síťovém prostředí prostřednictvím síťového protokolu TCP/IP. Také umožňuje různým periferním zařízením integraci do systému PACS (Picture Archiving and Communication System). [18] [27]

Datový objekt, obsahující obrazová data, je v každém souboru pouze jeden. Tento objekt může obsahovat jeden snímek nebo také sérii snímků od určitého subjektu. Obraz je možné uložit bez komprese nebo s využitím ztrátové komprese pomocí formátů JPEG, JPEG 2000 aj. [18] [27]

Soubor DICOM obsahuje kromě obrazových dat také hlavičku, kde jsou uloženy informace o subjektu (ID, jméno, příjmení, rok narození, apod.), akvizici (použitá modalita, akviziční doba, radiační dávka, velikost zorného pole, apod.) a o obrazu (velikost obrazu, formát, bitová hloubka, apod.). Díky tomuto nedochází k nechtěným záměnám informací o pacientech a jejich vyšetřeních. [18] [27]

## 2 PUBLIKOVANÉ SEGMENTAČNÍ METODY

Přestože bylo publikováno mnoho vědeckých prací zabývajících se automatickou segmentací kostních struktur v obrazových CT datech, zůstává tato úloha stále signifikantním problémem, kterým je potřeba se zabývat. Existuje řada faktorů značně komplikujících plně automatickou segmentaci kostních struktur od ostatních tkání. Jedná se např. o nehomogenitu tkáně, kde kortikální části vykazují výrazně vyšší modulaci PP než části trabekulární, které se navíc, dle stupnice na obr. 1.1, překrývají v Hounsfieldových jednotkách s měkkými tkáněmi. Dalším faktorem komplikujícím automatickou segmentaci jsou např. různé patologie (osteoporóza, fraktury, nádory aj.), rozmazání sejmutých dat (např. pohybová neostrost) apod. Nedílným požadavkem pro kvalitní automatickou segmentaci je kromě přesnosti a spolehlivosti také otázka výpočetní náročnosti implementované metody.

V následujících kapitolách jsou postupně popsány a rozebrány vybrané publikované metody a algoritmy zabývající se segmentací kostních struktur v obrazových CT datech. Výsledky vybraných metod jsou demonstrovány na obrázcích převzatých z publikací.

### 2.1 Kangova metoda


Jedná se o metodu publikovanou v [14]. Zabývá se 3D segmentací kostních struktur v objemových CT datech. Vícekrokový přístup je založen na metodě narůstání oblasti (*angl.* region growing) implementované ve 3D prostoru využívající lokálně adaptivní kritérium, následované algoritmem pro korekci kostních nespojitostí. Nakonec se provede úprava anatomicky orientovaných hranic s využitím lokálních hodnot hustoty kortikálních částí kostí.

V prvním kroku je aplikována 3D metoda narůstání oblasti využívající lokálně adaptivní kritérium, kde z histogramu z celého objemu dat (obr. 2.1a) jsou určeny dva globální prahy (LT a HT), podle kterých všechny voxely s nižším CT číslem než LT jsou automaticky označeny jako měkká tkáň a obdobně voxely s vyšším CT číslem než HT jako kostní tkáň. Lokálně adaptivní kritérium je použito u voxelů spadajících mezi tyto dva globálně stanovené prahy. Kritérium je založeno na střední hodnotě  $m$  a směrodatné odchylce  $SD$  šestadvaceti okolů právě testovaného voxelu  $v$ , kde výsledné přiřazení k měkké tkáni nebo kosti definuje vztah

$$CT_v = \begin{cases} < m - \alpha SD & \Rightarrow \text{přiřazeno k měkké tkáni} \\ \geq m - \alpha SD & \Rightarrow \text{přiřazeno ke kosti} \end{cases}, \quad (2.1)$$

kde  $\alpha$  je konstanta typicky rovná jedné. Automatické určení globálních prahů LT a HT je založeno na úvaze, že rozložení CT čísel v histogramu lze aproximovat

pomocí dvou normálních (Gaussových) rozdělení, kde první reprezentuje rozložení měkkých tkání a druhé kostních struktur (viz obr. 2.1b). Práh LT je odvozen jako součet CT čísla v průsečíku  $p_2$  s CT číslem  $B_s$  (střední hodnota rozdělení reprezentující měkkou tkáň). Práh HT je následně určen přičtením 400 HU k LT.




Obr. 2.1: Histogram CT čísel objemových dat: (a) histogram s vyznačením globálních prahů; (b) proložení histogramu Gaussovými funkcemi. [14]

Druhý krok se zabývá korekcí nespojitosti hranic neboť metoda narůstání oblasti nedosahuje požadovaných výsledků, kde především v trabekulárních částech kostí se vyskytují nespojitosti hran nebo izolované voxely (obr. 2.2a). Tudíž jsou aplikovány rozdílné 2D a 3D operace pro uzavření děr. V každém 2D řezu jsou výsledkem 3D segmentace 2D kontury. Pokud jsou tyto kontury nepřerušené je jednoduché veškeré voxely uvnitř označit jako kost pomocí 2D algoritmu vyplnění kontur. Potíž nastává v situaci, kdy jsou kontury přerušené (obr. 2.2b).

Při aplikaci 3D morfologické operace uzavření se sférickým strukturálním elementem je výsledek výhodný pouze pro kortikální části kostí, v trabekulárních částech operace zanechává díry (obr. 2.2c). Z tohoto důvodu byla implementována speciální kombinace těchto dvou operací, kde mezi dilatační a erozní krok 3D operace uzavření je zařazeno 2D vyplnění kontur. Výsledek lze vidět na obr. 2.2d

Kvalita a přesnost prvních dvou segmentačních kroků je vizuálně poměrně dostatečující, avšak je závislá zejména na stanovení hodnot prahů LT, HT a konstantě  $\alpha$ . Také morfologické operace závisí na velikosti a tvaru strukturálního elementu a mohou proto podávat chybné výsledky. Konečný efekt představují vyhlazené hranice, které mohou být nežádoucí při požadavku na zachování menších struktur. Z těchto důvodů je aplikováno anatomicky orientované upřesnění založené na profilu CT čísel analyzovaném kolmo ke kortexu kosti. Původně byla tato metoda vyvinuta pro 2D segmentaci korikálních kostí v CT datech. [13] Toto upřesnění se sestává ze tří hlavních kroků: 1) triangulace povrchu získaného z druhého kroku segmentace;




Obr. 2.2: Výsledek segmentace I. a II. kroku (koronální pohled): (a) výsledek 3D narůstání oblasti; (b) 2D vyplnění kontur; (c) 3D morfologické uzavření; (d) kombinace metod (b) a (c). [14]

2) stanovení 50% prahu, což je polovina maximální CT hodnoty vyhlazeného profilu podél každé normály trojúhelníku. Díky prahu je poté známa tloušťka v pixelech kortikální části kosti; 3) přispůsobení triangulačního povrchu. Délka profilů je dynamicky upravena na základě kolísání tloušťky kortikální kosti. Profil intenzity byl vyhlazen průměrujícím oknem o délce pěti pixelů.

Segmentace periostu (okostice) je získána pomocí tří segmentačních kroků popsaných výše. Segmentaci endostu (vnitřní vazivová vrstva) obdržíme z finálního povrchu periostu, kdy jsou opět použity normály všech trojúhelníků triangulačního povrchu. Zde je vzhledem ke stanovenému 50% prahu v profilu intenzity obdrženo množství voxelů rozptýlených na povrchu endostu nebo dokonce uvnitř trabekulární kosti (obr. 2.3a). Pro získání spojitého povrchu je opětovně použita 3D morfologická operace uzavření s implementovanou fází 2D vyplnění kontur. Finální výsledek reprezentuje obr. 2.3b.





Obr. 2.3: Segmentace endostu: (a) izolované voxely obdrženy dle 50% prahu; (b) finální výsledek segmentace po morfologických operacích. [14]

## 2.2 Segmentace s využitím 3D adaptivního prahování

Jedná se o rychlou, plně automatickou a robustní techniku pro segmentaci kostí v CT datech publikovanou v [31]. Metoda se skládá ze tří hlavních kroků: počáteční prahování s globálním prahem, automatické zaplavování (*angl.* floodfilling) a iterativně adaptivní prahování.


Počáteční prahování slouží k získání výchozích kontur 3D povrchu kostí. Je aplikována relativně nízká hodnota prahu, aby se zabránilo vzniku nespojitostí, které by měly negativní vliv při následném zaplavování. Hodnota prahu je stanovena obdobně jako v 2.1 na základě myšlenky, že měkké tkáně a kosti lze v histogramu CT čísel aproximovat pomocí dvou normálních (Gaussových) rozdělení. Počáteční práh je poté definován jako průsečík těchto dvou rozdělení. Tímto je získán binární obraz, kde každý pixel s hodnotou rovnou nebo vyšší než práh je zařazen do třídy  $B$  (kostní tkáň) a pixely s nižší hodnotou než práh do  $\bar{B}$  (ostatní tkáň).

Na obr. 2.4b lze vidět výsledek počátečního prahování, kde trabekulární části kostí mají tendenci k chybnému zařazení. Uvnitř kostí poté vznikají díry, které jsou plně ohraničeny kortikálními částmi zařazenými do třídy  $B$ .  $\bar{B}$  může být zapsáno jako

$$\bar{B} = \bar{B}_T \cup B_1 \cup B_2 \cup B_3 \cdots \cup B_n, \quad (2.2)$$

kde  $\bar{B}_T$  je region neobsahující kostní tkáň,  $B_i$ , kde  $i = 1, 2, \dots, n$  představuje regiony chybně klasifikovaných trabekulárních kostí.

Poté je aplikován algoritmus zaplavování, kde v první řadě jsou lokalizovány všechny pixely  $u \in \bar{B}_T$ , resp. testuje se každý pixel  $v \in \bar{B}$  a pokud splňuje podmínku, že je alespoň jedním z 8-mi okolí  $u$  nebo je spojen s  $w \in \bar{B}$  a  $w$  je spojen s  $u$ , tak pixel  $v$  je připojen k  $u$ . Tedy  $v$  je připojen k  $u$  jen a pouze pokud  $v \in \bar{B}_T$ . Výsledkem je extrakce  $\bar{B}_T$  a překlasifikování chybně označených regionů trabekulárních částí kostí (obr. 2.4c).



Obr. 2.4: Ilustrace 2D segmentační procedury: (a) originální obraz; (b) výsledek počáteční segmentace; (c) výsledek zaplavování; (d) obraz po iterativně adaptivním prahování. [31]

Počáteční segmentací jsou získány regiony  $B$  a  $\bar{B}$ . Následná metoda 2D iterativně adaptivního prahování se skládá z těchto kroků:


- Nalezení všech hraničních pixelů z počáteční segmentace (jako hraniční je pixel

označen pokud alespoň jeden pixel z jeho okolí spadá do odlišné kategorie).

- Pro každý hraniční pixel
  - je vypočtena střední hodnota a rozptyl lokálního okolí pixelu definovaného oknem,
  - dle těchto hodnot je lokální okolí klasifikováno podle Bayesova rozhodovacího pravidla [2],
  - hraniční pixel je zařazen do chybové třídy  $R$ , pokud lokální okolí není klasifikováno jako kostní tkáň.
- Dle chybové třídy  $R$  se aktualizuje současná segmentace.
- Takto se cyklus opakuje až ke konvergenci (pokud do chybové třídy  $R$  není zařazen žádný hraniční pixel).

Výsledek iterativně adaptivního prahování reprezentuje obr. 2.4d.

Tato demonstrace využívala 2D adaptivní prahování, které může chybně segmentovat určité oblasti dat, např. kruhovitý region  $\bar{B}_{in}$  uprostřed obratle neobsahující kostní tkáň, který lze vidět na obr. 2.4b. Při následné reklasifikaci se region  $\bar{B}_{in}$  zařadí do třídy  $B$  neboť nesplňuje žádnou z výše zmíněných podmínek. Tento problém je však vyřešen použitím 3D metody adaptivního prahování, kde vzhledem k anatomickým vlastnostem obratle, je na některých řezech tento region uzavřený, zatímco na jiných spojen s pozadím. Díky této vlastnosti bude region  $\bar{B}_{in}$  správně překlasiifikován do třídy  $\bar{B}$ . Použití 3D metody vyžaduje při testování jednotlivých voxelů rozšíření okna definujícího okolí bodu o nejbližší voxel jak z předcházejícího, tak také následujícího řezu. Celkem je tedy vždy testováno 10-ti okolí voxelu. Konečný výsledek metody (červeně) spolu s porovnáním plně manuální segmentací (modře) lze vidět na obr. 2.5.



Obr. 2.5: Výsledek 3D adaptivního prahování. [31]

### 3 IMPLEMENTACE SEGMENTACE KORTIKÁLNÍCH ČÁSTÍ KOSTÍ

V této kapitole bude popsána implementace vlastního algoritmu sloužícího k segmentaci kortikálních částí kostí v objemových CT datech. Jednotlivé kroky implementované metody názorně popisuje přiložený vývojový diagram (obr. 3.1), kde po načtení dat je získána binární maska hlavy, sloužící pro potlačení struktur komplikujících segmentaci. Následně je stanoven globální práh dle proložení histogramu vhodným pravděpodobnostním rozdělením a konečně provedena segmentace prahováním dle stanoveného prahu. Jednotlivé bloky diagramu jsou detailněji popsány v následujících kapitolách.




Obr. 3.1: Vývojový diagram segmentace.

Testování funkčnosti metody je provedeno na objemových CT datech pěti subjektů, kde u každého subjektu bylo provedeno kompletní vyšetření hlavy. Použitý skener byl značky Philips, typ Brillance 64, kde každý sejmutý obraz má rozměr  $512 \times 512$  voxelů a je kvantován 16-ti bity. Rozlišení v axiálním směru, tedy tloušťka jednotlivých voxelů, nabývá 0,625 mm. Šířka voxelů v x a y směru nabývá 0,4297 mm.

### 3.1 Získání binární masky hlavy


Naskenovaná data obsahují mimo oblasti zájmu (hlava), také struktury, které se podílejí na modulaci PP a zároveň zasahují do zorného pole zobrazovacího systému. Mezi tyto struktury patří např. patientský stůl, který dle Hounsfieldovy stupnice vykazuje densitu na pomezí trabekulárních částí kostí a měkkých tkání. Při požadavku přesné segmentace kostí je nutno tyto struktury (patientský stůl a okolní vzduch) odstranit. Postup algoritmu vykonávajícího tuto proceduru reprezentuje vývojový diagram na obr. 3.2.



Obr. 3.2: Vývojový diagram získání binární masky hlavy.

V prvním kroku jsou načtená objemová data ve formátu DICOM přetypována na typ double a normalizována v intervalu  $\langle 0; 1 \rangle$ . Poté je pro celý objem (na obr. 3.3a lze vidět řez objemem vstupních dat) určena optimální hodnota globálního prahu pomocí Otsu algoritmu, který je založen na hledání minima sumy rozptylů intenzit v popředí a pozadí histogramu analyzovaného obrazu [19]. Dle stanoveného prahu je poté provedena segmentace prahováním, čímž je získán binární obraz (obr. 3.3b).

Následně jsou v binárním obrazu nalezeny a zároveň označeny jednotlivé regiony pomocí testování konektivity čtyř okolů bodu. Vizuálně lze vidět, že největší re-



Obr. 3.3: Postup získání binární masky hlavy: (a) originální obraz; (b) prahovaný obraz; (c) binární maska hlavy; (d) násobení masky s originálním obrazem.

gion představuje vždy hlavu, dle této apriorní znalosti je provedeno měření objemu, resp. zjištění počtu voxelů obsažených v jednotlivých označených regionech. Region s největším objemem je poté pokládán za oblast hlavy a ostatní označené regiony se neuvažují. Následně je provedena operace vyplnění děr, kdy neoznačené oblasti uvnitř regionu hlavy (např. paranasální siny) se přiřadí k tomuto regionu. Tímto je obdržena binární maska hlavy (obr. 3.3c), kterou se vynásobí originální obraz pro získání pouze oblasti zájmu a potlačení výše vyjmenovaných struktur komplikujících segmentaci (obr. 3.3d).

## 3.2 Proložení histogramu pravděpodobnostním rozdělením

Předzpracovaná data zbavená nežádoucích struktur lze následně použít k segmentaci kortikálních částí kostí. Toho je dosaženo pomocí prostého prahování, což je v tomto případě metoda dostatečně přesná, jednoduchá na implementaci a zároveň výpočetně nenáročná. Klíčovou roli zde hraje určení hodnoty prahu, který je stanoven z histogramu celého objemu dat (obr. 3.4 nebo 3.5). Je nutno podotknout, že histogram je kvantován 10-ti bity (stupnice obsahuje 1024 hodnot) a je vypočten pouze z oblastí zájmu definovaných maskami hlavy získanými v předcházejícím kroku, což dokazuje nepřítomnost signifikantního píku v oblasti velmi nízkých intenzit charakterizujícího okolní vzduch. Lze tedy pozorovat pouze jeden výrazný pík, který reprezentuje měkké tkáně. Intenzity náležící kostní tkáni nevytvářejí žádný zřetelný pík neboť jsou rozprostřeny v pravé části histogramu. Na základě této skutečnosti je nutné práh pro segmentaci kortikálních částí kostí odhadnout pomocí detekce pozice píku náležícího měkkým tkáním.

Pík reprezentující rozložení měkkých tkání lze aproximovat vhodným pravděpodobnostním rozdělením. Dle parametrů vybraného rozdělení lze poté získat představu o tvaru píku a tedy určit hodnotu prahu pro následnou segmentaci prahováním. V implementaci jsou použity dva druhy rozdělení: normální (Gaussovo) a Pearsonovo rozdělení typu VII. Dle pozice a velikosti píku je nejdříve stanoveno počáteční proložení vybraným rozdělením. Následně je aplikována jedna z implementovaných optimalizačních metod sloužících k optimalizaci parametrů vybraného rozdělení, resp. tzv. optimálnímu proložení píku danou funkcí. Konkrétně se jedná o metody: úplné prohledávání (*angl.* exhaustive search), náhodné prohledávání (*angl.* random search) nebo matematickou metodu nejmenších čtverců (*angl.* least squares, LSQ). Podrobný popis zmíněných optimalizačních metod lze nalézt v [6], [24].


V následujících podkapitolách jsou rozebrány zmíněné implementované druhy rozdělení a také stručně popsány optimalizační algoritmy.

### 3.2.1 Normální (Gaussovo) rozdělení

Řadu fyzikálních či chemických procesů lze popsat normálním (Gaussovým) pravděpodobnostním rozdělením. Toto rozdělení se v praxi vyskytuje nejčastěji a také mnoho jiných rozdělení se jím dá nahradit. Dle této úvahy je předpokládáno, že rozložení měkkých tkání v histogramu lze aproximovat pomocí normálního rozdělení definovaného Gaussovou funkcí

$$f(x) = a e^{\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)}, \quad (3.1)$$

kde  $a$  představuje výšku vrcholu v bodě  $\mu$  (střední hodnota) a parametr  $\sigma$  (směrodatná odchylka) ovlivňuje šířku píku. [3] [6] [14]



Obr. 3.4: Histogram stupňů šedi objemových dat proložený Gaussovou funkcí.

Detekce pozice maxima v histogramu, které vždy náleží píku reprezentujícímu měkké tkáně, slouží jako počáteční odhad parametrů  $a$  a  $\mu$  výchozí Gaussovy funkce (červená křivka na obr. 3.4). Parametr  $\sigma$  je empiricky nastaven na hodnotu 0,015.

Následná optimalizace výchozí Gaussovy funkce, resp. její „nařívání“ na histogram, spočívá v nalezení optimální hodnoty parametru  $\sigma$ .

V případě použití algoritmu úplné prohledávání je optimalizačním problémem minimalizace střední kvadratické odchylky (*angl.* Mean Squared Error, MSE) dle vztahu

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2, \quad (3.2)$$

kde  $n$  představuje počet vzorků funkce,  $x$  je histogram a  $\hat{x}$  odhad funkce. Obor hodnot hledaného parametru  $\sigma$  je  $\langle 0,0001; 0,015 \rangle$  se vzorkovacím krokem 0,0001. Jinými slovy je napříč oborem hodnot hledán takový parametr  $\sigma$ , pro který je testovaná kritériální hodnota minimální. Vzhledem k tomu, že se optimalizuje pouze jeden parametr a obor hodnot není rozsáhlý (150 hodnot), tak doba potřebná pro výpočet algoritmu je velmi krátká. [7]

Při zvolení metody náhodné prohledávání je optimalizační problém naprosto stejný, tedy minimalizace kritériální hodnoty MSE. Rozdíl spočívá v tom, že zde je zadán počet iterací cyklu (v programu nastaveno na 1000), kdy se vždy náhodně



vygeneruje hodnota  $\sigma$  z výše zmíněného oboru hodnot, dle které se určí kritériální hodnota ze vztahu (3.2).

Třetí možnost optimalizace parametru  $\sigma$  je s využitím metody LSQ za pomoci funkce `lsqcurvefit` v prostředí MATLAB<sup>®</sup>, kde vstupem je předpis Gaussovy funkce dle (3.1), počáteční odhad funkce, histogram a interval parametrů funkce ve kterém se má hledat optimální řešení. Samotná optimalizace poté spočítá ve smyslu řešení nelineární metody nejmenších čtverců.

Dle zvoleného optimalizačního algoritmu jsou obdrženy parametry Gaussovy funkce, která aproximuje rozložení měkkých tkání v histogramu (zelená křivka na obr. 3.4).

### 3.2.2 Pearsonovo rozdělení typu VII

V různých odvětvích RTG krystalografie se pro popis tvaru píku s oblibou používá Pearsonovo rozdělení typu VII. Je odvozeno od Pearsonova rozdělení typu IV, do něhož je za parametr, který ovlivňuje šikmost, dosazena nula. Tímto je obdrženo stranově symetrické rozdělení, které popisuje funkce:


$$f(x) = c \left[ 1 + \frac{(x - \bar{x})^2}{ma^2} \right]^{-m}, \quad (3.3)$$

kde  $c$  představuje výšku vrcholu v bodě  $\bar{x}$ , parametr  $a$  definuje šířku píku a  $m$  ovlivňuje pouze špičatost funkce. Ve speciálním případě, kdy parametr  $m = 1$ , přechází toto rozdělení v Cauchy-Lorentzovo a při  $m \rightarrow \infty$  v normální (Gaussovo) rozdělení. [3] [9] [15]

Při vizuálním pohledu na histogram lze vidět, že pík reprezentující rozložení měkkých tkání je prakticky vždy symetrický, velmi špičatý a vysoký. Dle těchto apriorních znalostí je použito právě Pearsonovo rozdělení typu VII, kde především parametr  $m$  kontrolující špičatost funkce má pozitivní vliv při následném optimalizování výchozí funkce.

Obdobně jako v případě použití Gaussova rozdělení, slouží detekovaná pozice maxima v histogramu jako počáteční odhad parametrů  $c$  a  $\bar{x}$  výchozí Pearsonovy funkce (červená křivka na obr. 3.5). Ostatní parametry jsou nastaveny empiricky:  $a = 0,015$  a  $m = 3$ . Výchozí funkce, resp. parametry  $a$  a  $m$  jsou optimalizovány ve smyslu získání funkce aproximující rozložení měkkých tkání v histogramu.

U metod úplného nebo náhodného prohledávání je optimalizačním problémem minimalizace kritériální hodnoty MSE dle vztahu (3.2). Obor hodnot parametru  $a$  je  $\langle 0,0001; 0,015 \rangle$  se vzorkovacím krokem 0,0001 a parametru  $m$   $\langle 3; 7 \rangle$  se vzorkovacím krokem 0,1. Nyní se již optimalizují parametry dva, ale i v tomto případě je



Obr. 3.5: Histogram stupňů šedi objemových dat proložený Pearsonovou funkcí.

výpočetní náročnost algoritmu velmi nízká. U náhodného prohledávání probíhá optimalizace také 1000 iteračních cyklů. Metoda LSQ je realizována stejným způsobem jako v případě optimalizace Gaussovy funkce.

Optimalizovanou funkci reprezentuje zelená křivka na obr. 3.5. Lze si všimnout, že Pearsonova funkce daný pík aproximuje přesněji než funkce Gaussova, a to díky parametru  $m$ , který ovlivňuje špičatost.

### 3.3 Prahování s globálním prahem

Finální krok při segmentaci kortikálních částí kostí, tedy získání požadovaného segmentovaného obrazu, je dosaženo pomocí prahování předzpracovaného obrazu s globálním prahem, který je stanoven z optimalizované funkce (zelená křivka na obr. 3.4 a 3.5), resp. dle parametru definujícího šířku píku. Tímto způsobem je práh stanoven zcela automaticky a nezávisle na vstupních datech.


V případě použití normálního (Gaussova) rozdělení je globální práh (černá úsečka na obr. 3.4) stanoven empiricky jako  $\mu + 12\sigma$ . Poté se následně prahování každého voxelu  $x$ , dle jeho intenzity  $I(x)$  řídí vztahem

$$x = \begin{cases} 0 & I(x) < \mu + 12\sigma \\ 1 & I(x) \geq \mu + 12\sigma \end{cases} \quad (3.4)$$

Při zvolení Pearsonova rozdělení typu VII je globální práh (černá úsečka na obr. 3.5) stanoven velmi obdobným způsobem, konkrétně jako  $\bar{x} + 10a$ . Každý voxel  $x$  je poté testován vzhledem k jeho intenzitě  $I(x)$  dle vztahu

$$x = \begin{cases} 0 & I(x) < \bar{x} + 10a \\ 1 & I(x) \geq \bar{x} + 10a \end{cases} . \quad (3.5)$$

Obr. 3.6 demonstruje dosažené výsledky implementované metody na datech třech subjektů, kde horní řada představuje originální data a spodní segmentovaná. Pro názornost jsou binární masky, získané pomocí prostého prahování, vynásobené s původním obrazem. Prezentované výsledky představují jednotlivé snímky (řezy) z oblasti



Obr. 3.6: Výsledek segmentace kortikálních částí kostí: horní řada představuje originální data a spodní segmentovaná.

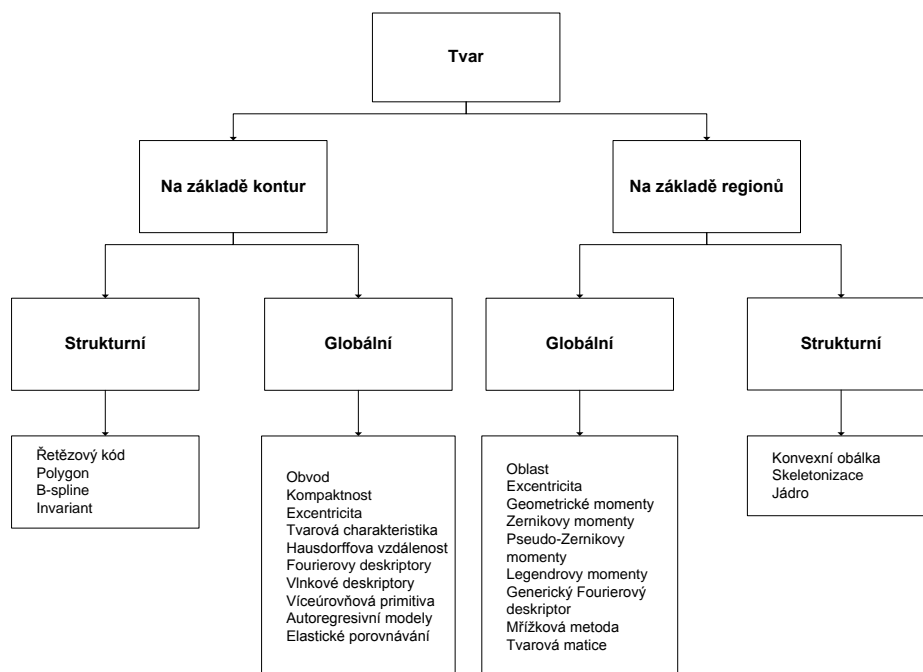
spodiny lebeční (*lat. basis cranii*), kde bývá segmentace kostních struktur ze snímků hlavy nejkomplicovanější. Lze si povšimnout, že kortikální části, které obecně v CT datech nabývají vysokých intenzit, jsou segmentovány správně. Pouze např. oblasti jako sluchové či nosní kůstky, představující drobné kostní útvary, nebo kosti s velmi tenkou kortikální částí nevykazují vysokou modulaci PP a tudíž jejich intenzita nedosahuje hodnot jako ostatní kortikální části. V obrazu poté vznikají nedokonale (přerušeně) segmentované struktury. Hodnota globálního prahu je stanovena tak, aby ve

velké míře byly segmentovány také trabekulární části kostí, které se v Hounsfieldových jednotkách nepřekrývají s měkkými tkáněmi. Díky tomu lze v segmentovaném obrazu nalézt typické díry uvnitř trabekulárních částí odpovídající právě regionům překrývajícím se v Hounsfieldových jednotkách s měkkým tkáněmi.

## 4 TVAROVÁ KLASIFIKACE

Analýza a reprezentace tvarů v digitálním obrazu, popřípadě jejich klasifikace, je velmi rozsáhlá oblast spadající do oboru počítačové grafiky. Tvar je důležitý vizuální příznak používaný lidmi odjakživa k popisu obrazového obsahu, avšak tvar jako takový nelze jednoduše formalizovat nebo matematicky popsat. Pokud budeme chtít tvary úspěšně analyzovat, musíme přesně znát jaké vlastnosti vykazují a často také brát v potaz způsob, jakým jsou vnímány lidmi. Např. neuron, který může zaujímat nekonečně mnoho tvarů, které ale vykazují jistou charakteristiku - mnoho větví, díky čemuž lze říct, že se jedná o neuron. Reprezentací tvaru rozumíme ve smyslu stanovení dostatečného množství charakterizujících příznaků z kterých lze poté rekonstruovat původní tvar s danou přesností. V případě klasifikace se jedná o nalezení daného objektu v obrazu a jeho zařazení do správné třídy dle určitého vektoru příznaků. [4] [30]

Zde bude tvar chápán jako jakékoliv množství spojených bodů, které lze popsat různými příznaky založenými buď na informacích odvozených z obrysu nebo objektu jako celku. Dle toho dělíme techniky reprezentace tvarů na základě kontur nebo regionů, ty lze hlouběji rozdělit na strukturní nebo globální, v závislosti na faktu zda je tvar reprezentován jako celek, či pomocí primitiv. Kompletní hierarchii možností, kterými lze kvantitativně popisovat tvary objektů v obrazu znázorňuje obr. 4.1. [4] [30]



Obr. 4.1: Možnosti reprezentace tvarů v obrazu. [30]

Vstupní obrazová data představují segmentované kosti a úkolem je nalézt nedostatečně segmentované (přerušené) části kostních struktur, které jsou reprezentovány především konturami, budou zde proto rozebrány pouze možnosti popisující tvary objektů na základě kontur.

## 4.1 Globální reprezentace tvaru na základě kontur

Globální neboli spojitý přístup nerozděluje tvar na jednotlivé segmenty, ale obvykle k popisu objektu získá vektor příznaků z kompletní kontury. Případné testování tvarové podobnosti objektů pak spočívá převážně v měření metrické vzdálenosti mezi obdrženými vektory příznaků (např. Euklidovská vzdálenost). V následujících podkapitolách budou postupně rozebrány tvarové deskriptory využívající globální reprezentaci tvaru na základě kontur. [30]

### 4.1.1 Jednoduché tvarové deskriptory

Tyto deskriptory jsou založeny na měření komplexity tvaru pomocí různých parametrů jako jsou např. obvod, plocha, kruhovitost (obvod<sup>2</sup>/plocha), excentricita (poměr délký hlavní a vedlejší osy), orientace hlavní osy, kompaktnost (poměr obvodu kruhu o stejné ploše jako originální objekt a originálního obvodu), kruhová, či eliptická variance, konvexnost (poměr obvodu konvexní obálky s originálním obvodem) nebo tzv. ohybová energie (*angl.* bending energy), která udává množství energie, kterou musí počáteční objekt (např. kružnice) vynaložit, aby změnil svůj tvar na analyzovaný objekt. [21] [28] [30]

Zmíněné jednoduché globální deskriptory dokáží pouze klasifikovat výrazně odlišné tvary. Využití je např. jako prvotní filtr, který eliminuje objekty s velmi odlišnými tvary, zbylé přenechá kvalitnějším deskriptorům nebo kombinaci více jednodušších. [30]

### 4.1.2 Tvarové porovnávání založené na korespondenci

Deskriptory založené na korespondenci pracují v prostorové oblasti, ale namísto reprezentace tvaru pomocí příznaků, využívají měření podobnosti mezi objekty bod po bodu. Jinými slovy je na každý bod objektu pohlíženo jako na příznak. [30]

Typickým příkladem je např. Hausdorffova vzdálenost, používaná k lokalizaci objektů v obrazu a měření podobnosti mezi tvary. Mějme dva objekty  $A$  a  $B$ , které jsou reprezentovány množinou bodů:  $A = \{a_1, a_2, \dots, a_p\}$  a  $B = \{b_1, b_2, \dots, b_q\}$ , poté Hausdorffova vzdálenost  $H$  mezi  $A$  a  $B$  je definována jako


$$H(A, B) = \max\{h(A, B), h(B, A)\}, \quad (4.1)$$

kde

$$h(A, B) = \max_{a \in A} \{ \min_{b \in B} \|a - b\| \}, \quad (4.2)$$

přičemž  $\|\cdot\|$  zde značí metrickou vzdálenost (např. Euklidovskou). Výhoda metody spočívá v možném porovnávání tvarů po částech. Hausdorffova vzdálenost je velmi citlivá na případně se vyskytující šum v obrazu a také není invariantní vůči translaci, rotaci a změně měřítka, z čehož plynou značné nároky na výpočetní výkon neboť je potřeba testovat podobnosti při různém nastavení obrazové transformace. [30]

Další metodou založenou na korespondenci je porovnávání objektů s využitím tvarových souvislostí (*angl.* shape contexts). Jedná se o zdokonalení Hausdorffovy vzdálenosti ve smyslu získání globálního příznaku nazývaného tvarová souvislost pro každý korespondující bod. Mějme dva originální objekty reprezentovány diskrétní množinou bodů (obr. 4.2a a 4.2b). Uvažujme soubor vektorů vycházejících



Obr. 4.2: Tvarové souvislosti: (a,b) originální objekty reprezentované množinou diskrétních bodů; (c-e) histogramy (tvarové souvislosti) pro dané referenční body (v pořadí  $\circ$ ,  $\diamond$ ,  $\triangleleft$ ). [1]

z jednoho referenčního bodu ke všem ostatním bodům daného objektu. Tyto vektory poté vyjadřují konfiguraci tvaru vzhledem k referenčnímu bodu. Evidentně čím větším počtem bodů bude daný objekt vyjádřen, tím bude reprezentace tvaru přesnější. Takto stanovený soubor vektorů je ale příliš rozsáhlý, proto je na základě délky  $r$  jednotlivých vektorů a jejich orientaci  $\theta$  sestrojen histogram (tvarová souvislost) v log-polárním souřadnicovém systému, který reprezentuje tvar dle referenčního bodu. Histogram pro každý referenční bod daného objektu je následně ekvalizován a spojen s ostatními k vytvoření tzv. mapy tvarových souvislostí, což si můžeme představit jako matici, kde každý řádek představuje jeden ekvalizovaný histogram. Následná klasifikace dvou objektů spočívá v porovnávání dvou matic. Na obr. 4.2c - 4.2e lze vidět jednotlivé histogramy pro referenční body (v originálním obrazu označeny jako  $\circ$ ,  $\diamond$ ,  $\triangleleft$ ). Mezi histogramy 4.2c a 4.2d vidíme podobnost, neboť byly sestrojeny pro relativně podobné referenční body ( $\circ$  a  $\diamond$ ). Histogram náležící referenčnímu bodu  $\triangleleft$  (obr. 4.2e) je vzhledem k předchozím dvěma odlišný. [1] [30]

### 4.1.3 Tvarové charakteristiky

Jedná se o skupinu deskriptorů (*angl.* shape signatures) reprezentujících daný tvar pomocí jednorozměrné funkce odvozené ze souřadnic bodů extrahované kontury. Dochází tedy k redukci dimenze. Dokáží zachytit percepční příznaky tvaru. Většina těchto deskriptorů je odvozena relativně k těžišti analyzovaného objektu. Zde spadá např. funkce  $r(n)$  popisující vzdálenost bodů kontury od těžiště

$$r(n) = \sqrt{(x(n) - g_x)^2 + (y(n) - g_y)^2}, \quad (4.3)$$

kde  $(x(n), y(n))$  jsou souřadnice bodů kontury objektu a  $(g_x, g_y)$  těžiště. Funkce je vlivem subtrakce těžiště (reprezentuje pozici tvaru) od bodů kontury invariantní vůči translaci. [16] [30]

Jiným příkladem může být vyjádření funkce  $z(n)$  v komplexních souřadnicích

$$z(n) = [x(n) - g_x] + [y(n) - g_y]i, \quad (4.4)$$

kdy hlavní myšlenka je transformovat tvar z  $\mathbb{R}^2$  do  $\mathbb{C}$ , kde lze poté aplikovat dodatečné transformace, např. konformní zobrazení. I zde platí invariantnost vůči translaci. [20]

Často používaná je funkce popisující směrový úhel tečny v každém bodě kontury. Směrový úhel  $\theta(n)$  v bodech kontury  $(x(n), y(n))$  je definován jako

$$\theta(n) = \arctan \left( \frac{y(n) - y(n - \omega)}{x(n) - x(n - \omega)} \right), \quad (4.5)$$

kde  $\omega$  reprezentuje malé okno potřebné k výpočtu úhlu, neboť kontura je zde digitální křivka. Je nutno zmínit, že takto obdržená funkce může vykazovat nespojitosti z důvodu, že směrový úhel je definován na intervalu  $\langle -\pi, \pi \rangle$  nebo  $\langle 0, 2\pi \rangle$ . Předejit tomuto problému lze pomocí kumulativní úhlové funkce  $\varphi(n)$ , definované jako rozdíl směrových úhlů mezi body kontury a startovního bodu

$$\varphi(n) = [\theta(n) - \theta(0)]. \quad (4.6)$$

Funkce popisující směrový úhel je invariantní vůči translaci. V případě normalizace, běžně v intervalu  $\langle 0, 2\pi \rangle$ , je zaručena také invariance vůči změně měřítka. [16] [20]

Jednorozměrnou funkci lze také získat dle úvahy, že vždy dva po sobě následující body kontury spolu s těžištěm tvoří trojúhelník jehož plocha se mění vlivem procházení všech možných po sobě následujících dvojic bodů kontury. Takovouto závislost poté vyjadřuje tzv. funkce plochy, která je lineárně závislá vůči afinní transformaci obrazu. [16] [20]

Další deskriptor je založen na tětivové vzdálenosti, která je definována následovně: mějme bod kontury P, nejkratší vzdálenost mezi P a jiným bodem kontury



$P'$ , přičemž  $PP' \perp$  tečný vektor v  $P$ , je těživová vzdálenost. Výsledná funkce tedy vyjadřuje změnu délky těživy podél obvodu analyzovaného tvaru. Je invariantní vůči translaci a nevyžaduje k výpočtu souřadnice těžiště. [16] [20]

Všechny zmíněné deskriptory reprezentující daný tvar pomocí jednorozměrné funkce jsou velmi citlivé na šum, i malá změna v tvaru způsobí velký rozdíl ve výsledné funkci. Z tohoto důvodu je potřeba aplikovat další zpracování, např. transformaci do spektrální oblasti nebo vytvoření charakterizujícího histogramu, který je navíc invariantní vůči rotaci. [30]

#### 4.1.4 Fourierovy deskriptory

Fourierovy deskriptory (FDs) reprezentují tvar ve spektrální oblasti. Jsou získány Fourierovou transformací (FT) jednorozměrné funkce - jedné z tvarových charakteristik, popsanych v 4.1.3. Spektrální deskriptory jsou obecně invariantní vůči translaci a změně měřítka. Vykazují robustnost vůči šumu a malým změnám tvaru analyzovaného objektu. FDs tvoří sekvenci amplitudových a fázových koeficientů  $\{(A_i, \alpha_i)\}_{i=0}^{N-1}$  diskrétní Fourierovy transformace (DFT) definované jako

$$F(s) = \sum_{x=0}^{N-1} f_R(x) e^{-j2\pi sx/N}, \quad s = 0, \dots, N-1, \quad (4.7)$$

kde  $f_R(x)$  představuje jednorozměrnou funkci a  $N$  počet vzorků funkce. Výpočet FDs je jednoduchý a pokud je zahrnuto všech  $N$  amplitudových a fázových komponent, je možné přesně zpětně rekonstruovat funkci  $f_R$ . Předpokládejme, že koeficienty jsou řazeny vzestupně dle frekvence, poté pouze prvních  $K$  nízkofrekvenčních komponent je dostačujících k hrubému popisu (aproximaci) tvaru a zároveň potlačení potenciálně se vyskytujícího šumu nebo mírných odchylek tvaru. V praxi se požaduje nízká hodnota  $K$  kvůli výpočetní náročnosti následné klasifikace. Nejčastěji se volí  $K$  v rozmezí 15 až 20, ale vždy je nutno přizpůsobit  $K$  dle konkrétnímu druhu aplikace. [26] [29] [30]

Mějme dvě jednorozměrné funkce  $f_A$  a  $f_B$  charakterizující regiony  $A$  a  $B$ . Pomocí DFT jsou obdrženy FDs  $\{(A_i, \alpha_i)\}_{i=0}^{N-1}$  a  $\{(B_i, \beta_i)\}_{i=0}^{N-1}$  daných funkcí. Následné měření podobnosti mezi regiony může být provedeno jako suma odchylek čtverců prvních  $K$  seřazených FDs

$$\|A, B\| = \frac{1}{K-1} \sum_{i=0}^{K-1} (A_i - B_i)^2. \quad (4.8)$$

Je nutno podotknout, že fázové koeficienty  $\alpha_i$  a  $\beta_i$  jsou vyžadovány k rekonstrukci signálu, ale vzhledem k tomu, že mají malou diskriminační schopnost, při měření podobnosti jsou uplatněny pouze amplitudové koeficienty  $A_i$  a  $B_i$ , které jsou navíc invariantní vůči rotaci, tedy zvolení startovního bodu. [26] [29]

Při rozpoznávání objektů a klasifikaci, zejména také pokud se jedná o online rozpoznávání, se FDs s oblibou využívají neboť jsou výpočetně nenáročné, dostatečně robustní vůči vyskytujícímu se šumu či mírným odchylkám tvaru a zachycují globální příznaky. K odvození FDs se nejčastěji využívá funkce v komplexních souřadnicích nebo kumulativní úhlová funkce. [30]

### 4.1.5 Vlnkové deskriptory

Jedná se o spektrální deskriptory založené na vlnkové transformaci (*angl.* Wavelet Transform, WT) jednorozměrné funkce - tvarové charakteristiky. FDs získané pomocí FT mají sice vysokou diskriminační schopnost, ale vlivem fyzikální podstaty FT zcela postrádají prostorové rozlišení, což může být nežádoucí při požadavku detekce konkrétních míst analyzovaného objektu, kde je sledován určitý příznak. Tento problém lze vyřešit použitím vlnkových deskriptorů (WDs), což jsou koeficienty obdržené pomocí WT, jejíž spojitá verze (*angl.* Continuous Wavelet Transform, CWT) je definovaná jako

$$U_{\Psi}(b, a) = \int_{-\infty}^{+\infty} u(t) \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) dt, \quad (4.9)$$

kde  $u(t)$  je vstupní signál,  $\Psi(t)$  představuje mateřskou vlnku, koeficient  $a$  reprezentuje dilataci (stlačení, roztažení) mateřské vlnky a koeficient  $b$  translaci (posun) vlnky. Člen  $\frac{1}{\sqrt{a}}$  slouží k normalizaci energie vlnky při změnách měřítka. Jedná se tedy o korelaci mezi vstupním signálem a příslušně roztaženou a posunutou vlnkou<sup>1</sup>. Výsledkem je dvojrozměrný obraz v časově-měřítkové oblasti. Z Heisenbergova principu neurčitosti vyplývá, že nelze současně přesně určit frekvenci a polohu jejího výskytu v čase. Z tohoto důvodu při zvyšování koeficientu  $a$  roste frekvenční rozlišení a klesá časové. Naopak při snižování koeficientu  $a$  roste časové rozlišení a klesá frekvenční. [4] [17] [30]

Obdržené WDs pro různě nastavené hodnoty měřítka  $a$  a translace  $b$  tvoří tzv. sadu deskriptorů. Pro nízké hodnoty měřítka (obvykle  $a < 1$ ) se jedná o tzv. detailní signál, který zachycuje jemné detaily a pro vyšší hodnoty měřítka (obvykle  $a > 1$ ) jde o aproximaci signálu popisující hrubý tvar analyzovaného objektu. Obecně k popisu a rozpoznání tvaru dostačuje relativně malé množství deskriptorů tvořících sadu (např. 32 nebo 64). Následné testování podobnosti tvaru dvou objektů je provedeno jako měření metrické vzdálenosti (např. Euklidovské) mezi WDs reprezentujícími dané tvary. [4] [17]

---

<sup>1</sup>Lze realizovat pomocí konvoluce mezi vstupním signálem a reverzní impulsní charakteristikou příslušně roztažené vlnky.

WDs nesplňují invarianci vůči rotaci, proto měření podobnosti je nutno provést pro všechny možné startovní pozice, což způsobuje vyšší výpočetní náročnost. Také z důvodu vysoké redundance CWT, se v praxi, především pro online rozpoznávání, WDs příliš nepoužívají. [30]

## 4.2 Strukturní reprezentace tvaru na základě kontur

Strukturní neboli diskrétní přístup rozděluje analyzovaný tvar, dle určitého kritéria, na jednotlivé segmenty nazývané primitiva. K reprezentaci poté využívá řetězec nebo graf (popřípadě strom). Testování podobnosti poté spočívá v porovnávání řetězců nebo grafů. V následujících podkapitolách budou stručně zmíněny některé tvarové deskriptory využívající strukturní reprezentaci tvaru na základě kontur. [30]

### 4.2.1 Řetězový kód

Řetězový kód (*angl.* chain code) popisuje objekt pomocí sekvence čísel reprezentujících orientaci vektorů o jednotkové délce. Pro názornost uvažujme masku

$$\begin{bmatrix} 3 & 2 & 1 \\ 4 & X & 0 \\ 5 & 6 & 7 \end{bmatrix}, \quad (4.10)$$

kde X představuje centrální pixel a čísla okolo reprezentují všechny možné orientace vektorů v osmi okolí bodu. Lze vidět, že čísla jsou seřazeny proti směru hodinových ručiček. Nyní mějme objekt vyjádřený pomocí kontury, kde masku (4.10) umístíme centrálním pixelem na zvolený startovní bod. Poté je vzhledem k startovnímu bodu zjištěna pozice sousedního pixelu ve směru proti hodinovým ručičkám. Tato pozice je vyjádřena příslušným číslem masky se kterým se sousední pixel kryje. Následně se maska posune na místo sousedního pixelu a proces se opakuje. Takto je postupováno dokud se nezapočítají všechny pixely dané kontury. Výsledek poté představuje řetězec čísel, které reprezentují orientaci vektorů o jednotkové délce. [4] [8] [30]

Je zřejmé, že obdržžený kód není invariantní vůči rotaci. Jednou z možností normalizace může být nalezení minimálního celého čísla kódu neboť na řetězový kód lze pohlížet i jako na číslo. Dle této úvahy, jako startovní pixel lze pokládat ten, pro který je hodnota celého čísla kódu minimální. [4] [30]

Díky vysoké frekvenci výskytu repetice v řetězci je možno využít proudové kódování. Vzhledem k tomu, že řetězový kód většinou nabývá velkých rozměrů a je citlivý na šum, jeho využití se uplatňuje pouze jako vstup pro vyšší úroveň zpracování, např. pro aproximaci polygonem. [4] [30]

## 4.2.2 Polygonální aproximace

Důležitým a náročným úkolem tvarové analýzy je rozdělení kontury na významné části. Dekompozice kontury na jednotlivé segmenty má řadu využití, např. pro syntaktické rozpoznávání tvarů nebo rozpoznávání založené na porovnávání geometrických modelů. Dekompozice kontury může být rozdělena do dvou kroků, kde první slouží k určení významných bodů (vrcholů) kontury a druhý k reprezentaci daného segmentu mezi významnými body pomocí geometrického primitiva. Nejjednodušší a v praxi často používané primitivum je úsečka. Výstup poté představuje tzv. polygonální aproximaci kontury. Problémem polygonální aproximace je nalezení vhodných vrcholů kontury tak, aby byla obdržena pokud možno co nejlepší aproximace analyzované kontury. Klasický přístup řešení spočívá v uvažování bodů, které vykazují vysoký modul křivosti podél obvodu kontury. [4]

Metody pro detekci vrcholů a polygonální aproximaci mohou být rozděleny do dvou hlavních tříd: globální a lokální. Globální metody jsou obecně založeny na polygonální aproximaci kontury ve smyslu minimalizace kriteriální funkce, kterou může být např. maximální povolená vzdálenost mezi úsečkovými segmenty polygonu a odpovídajícími segmenty kontury. Tohoto přístupu využívá tzv. Ramerův algoritmus, který pomocí rozdělování úsečkových segmentů polygonu mezi počátečním odhadem vrcholů nalezne vhodné vrcholy, kde polygonální aproximace splňuje podmínku kriteriální funkce (podrobněji v [4]). Na druhé straně, lokální metody jsou založeny na myšlence přímého hledání bodů, které vykazují vysoký modul křivosti podél obvodu kontury. Toho lze dosáhnout různými technikami, např. pomocí neuronových sítí, rozložení elektrického náboje, či nelineárních algoritmů. [4] [22]


## 5 IMPLEMENTACE VYBRANÝCH TVAROVÝCH DESKRIPTORŮ

V této kapitole budou na segmentovaných datech demonstrovány implementované tvarové deskriptory, které budou využity pro následnou detekci potenciálně chybně segmentovaných (přerušených) částí kostí, což zahrnuje jak skutečně přerušené části kostí vlivem segmentace, tak i např. výduť v kosti do které zasahuje měkká tkáň, apod. Tyto případy ovšem nemohou být pomocí tvarových deskriptorů odlišeny (pro odlišení těchto případů by se musely použít dodatečně jiné metody), z tohoto důvodu je v textu používán výraz potenciálně přerušené kosti. Implementace je provedena v programovém prostředí MATLAB®.

### 5.1 Extrakce kontur

Vzhledem k faktu, že aplikované tvarové deskriptory jsou založeny na globální reprezentaci tvaru na základě kontur, je nutné ze segmentovaných dat v první řadě extrahovat kontury.


V prvním kroku extrakce kontur je provedeno označení binárních regionů, získaných segmentací v předcházející části, pomocí testování konektivity čtyř okolí pixelu s využitím funkce `bwlabel`. Výstup představuje matice o stejné velikosti jako vstupní obraz a informace o počtu nalezených regionů. Jednotlivé elementy matice obsahují celá čísla označující nalezené regiony, přičemž 0 náleží pozadí.



Obr. 5.1: Extrakce kontur: (a) binární obraz reprezentující segmentované kosti; (b) výstup po aplikaci morfologické operace odstranění vnitřních pixelů.

Na označené regiony je poté aplikována morfologická operace pro odstranění všech vnitřních pixelů. Jedná se o nastavení intenzity pixelu na 0, pokud všechny pixely ve čtyř okolí mají hodnotu 1. Na obr. 5.1 lze vidět výsledek extrakce kontury pro vybraný řez objemu (originální obraz před segmentací lze vidět na obr. A.1a), kde na vybrané kontuře v obr. 5.1b, vyznačené červenou oblastí, bude demonstrována aplikace tvarových deskriptorů, přičemž u této kontury došlo vlivem segmentace k přerušení kostní struktury na čtyřech místech, konkrétně se jedná o rohové výběžky po stranách kontury.

V dalším kroku je v cyklu na každou obdrženou konturu aplikován algoritmus sledování kontury pomocí funkce `bwtraceboundary`, kde jako startovní bod je vybrán pixel kontury s nejnižší y-ovou poziční souřadnicí obrazu. Sledování kontury postupuje ve směru hodinových ručiček. Tímto je obdržen vektor pozičních souřadnic pixelů, reprezentující danou konturu, který lze využít k aplikaci tvarových deskriptorů. Obdrženou posloupnost pixelů pro vybranou konturu, vykreslenou v kartézských souřadnicích, lze vidět na obr. 5.2.




Obr. 5.2: Sledování kontury: (a) vybraná kontura z obrazu; (b) výsledek sledování kontury.

## 5.2 Funkce vzdálenosti od těžiště

Jednorozměrná funkce popisující vzdálenost bodů extrahované kontury od těžiště binárního objektu je obdržena dle vztahu (4.3)<sup>1</sup>. Osa  $x$  představuje pořadové číslo pixelu podél obvodu kontury a na ose  $y$  je vynesena vypočtená vzdálenost procházejících bodů od těžiště. Lze vidět, že odvozená funkce (obr. 5.3a) obsahuje značné extrémy, které charakterizují výraznou změnu vzdálenosti od těžiště. Dle této apriorní znalosti je možno usuzovat, že tyto extrémy odpovídají místům, kde došlo k přerušení segmentace kosti. Při vizuálním pohledu ale tyto extrémy zachycují pouze hrubý tvar analyzovaného objektu, kdežto místa, ve kterých došlo k přerušení segmentace kosti vykazují často velmi nepatrnou změnu ve vzdálenosti od těžiště. Tudíž

<sup>1</sup>Připomeňme, že stejný průběh lze obdržet využitím funkce v komplexních souřadnicích dle (4.4) a uvažováním pouze absolutní hodnoty funkce.


je velmi obtížné detekovat konkrétní body, díky kterým by bylo možné spolehlivě rozhodnout, zda se jedná o přerušenu část kortikální kosti, či nikoliv. Situaci navíc komplikuje výskyt vysoce členitých kontur. Z těchto důvodů je deskriptor pro tento typ aplikace prakticky nepoužitelný.



Obr. 5.3: Funkce vzdálenosti od těžiště: (a) funkce s vyznačenými body náležícím chybně segmentovaným místům; (b) analyzovaná kontura se zvýrazněnými chybně segmentovanými místy (červeně) a těžištěm (zeleně).

### 5.3 Kumulativní úhlová funkce


Z obdržené posloupnosti pixelů analyzované kontury je odvozena jednorozměrná funkce reprezentující daný tvar. Pro tuto aplikaci je implementovaná funkce  $\theta(n)$ , popisující směrový úhel tečny v každém bodě kontury, dle vztahu (4.5), kde  $\omega$  reprezentující malé okno, je empiricky nastavena na hodnotu 10. Pro vybranou konturu reprezentuje obdrženou úhlovou funkci obr. 5.4a. Lze vidět, že funkce obsahuje množství nespojitostí, to je způsobeno faktem, že směrový úhel je definován pouze na intervalu  $\langle -\pi, \pi \rangle$  nebo  $\langle 0, 2\pi \rangle$ . Pro odstranění tohoto problému je aplikována kumulativní úhlová funkce  $\varphi(n)$ , dle vztahu (4.6), definovaná jako rozdíl směrových úhlů mezi body kontury a startovního bodu. Kumulativní proto, neboť reprezentuje postupnou sumaci úhlové změny každého bodu kontury. Výslednou funkci pro extrahovanou konturu, po odstranění nespojitostí, lze vidět na obr. 5.4b, kde zakreslené červené body náležejí chybně segmentovaným místům vyskytujícím se v kontuře na obr. 5.3b. Tento typ deskriptoru je v práci využit pro detekci potenciálně chybně segmentovaných kostí, neboť náhlé změny v obdržené funkci (lze si všimnout, že se jedná o inflexní body) reprezentují místa v kontuře, kde došlo k prudkým změnám sledovaného úhlu. Funkce je proto schopna spolehlivě zaznamenat i malé členité útvary - výběžky, kterými jsou často místa přerušené segmentace reprezentovány.



Obr. 5.4: Kumulativní úhlová funkce: (a) funkce popisující směrový úhel tečny s vyznačenými body náležícími chybně segmentovaným místům; (b) funkce po odstranění nespojitostí s vyznačenými body náležícími chybně segmentovaným místům.

## 5.4 Funkce popisující směrnicí tečny

Pomocí kumulativní úhlové funkce lze reprezentovat pouze tvar kontur, jejichž délka je větší než 10 pixelů, tento fakt plyne z důvodu výpočtu diferencí u funkce  $\theta(n)$ , dle vztahu (4.5), kde okno  $\omega$  je nastaveno na hodnotu 10. Z tohoto důvodu je nutné



Obr. 5.5: Funkce popisující směrnicí tečny: (a) vstupní binární region - segmentovaná kost; (b) získaná kontura; (c) obdržaná funkce.

ošetřit výskyt kontur s délkou menší nebo rovnou 10 pixelů. Toho je dosaženo pomocí funkce popisující směrnicí tečny v každém bodě kontury, bez výpočtu diferencí, dle vztahu


$$\theta(n) = \arctan \left( \frac{y(n)}{x(n)} \right), \quad (5.1)$$



kde  $(x(n), y(n))$  jsou souřadnice bodů kontury analyzovaného tvaru. Obr. 5.5 demonstruje postup aplikace funkce popisující směrnicí tečny na velmi malý region, jehož extrahovaná kontura má délku 10 pixelů. Z důvodu možného výskytu nespojitostí ve výsledné funkci je aplikováno rozbalení fáze pomocí funkce `unwrap`.

## 5.5 Fourierovy deskriptory

Jak již bylo řečeno, FDs reprezentují tvar ve spektrální oblasti. Zde je na vstupním signálu, kterým je kumulativní úhlová funkce (viz obr. 5.4b) demonstrována aplikace FDs. Kumulativní úhlová funkce je diskrétní, proto je frekvenční spektrum vypočteno pomocí DFT, resp. FFT (rychlá Fourierova transformace, *angl.* Fast Fourier Transform). Z obdrženého spektra je následně k popisu tvaru uvažováno pouze prvních  $K$  nízkofrekvenčních komponent. Zpětnou FT prvních  $K$  FDs je obdržen signál aproximující kumulativní úhlovou funkci. Vliv hodnoty  $K$  na tvar rekonstruované funkce pomocí FDs demonstruje obr. 5.6. Lze vidět, že pro  $K = 8$  je rekonstruovaná funkce pouze hrubou aproximací, pro  $K = 16$  se více blíží průběhu původní funkce a pro  $K = 32$  je rekonstruovaná funkce schopna zaznamenat i jemnější detaily dané výskytem vyšších harmonických složek. Pro případnou klasifikaci nebo vzájemné porovnávání kontur by takovýto počet FDs byl dostatečný, ale jak bylo zmíněno v 4.1.5, FDs zcela postrádají časové, či prostorové rozlišení. Z tohoto důvodu nelze pomocí FDs detekovat pozice chybně segmentovaných kortikálních částí kostí.



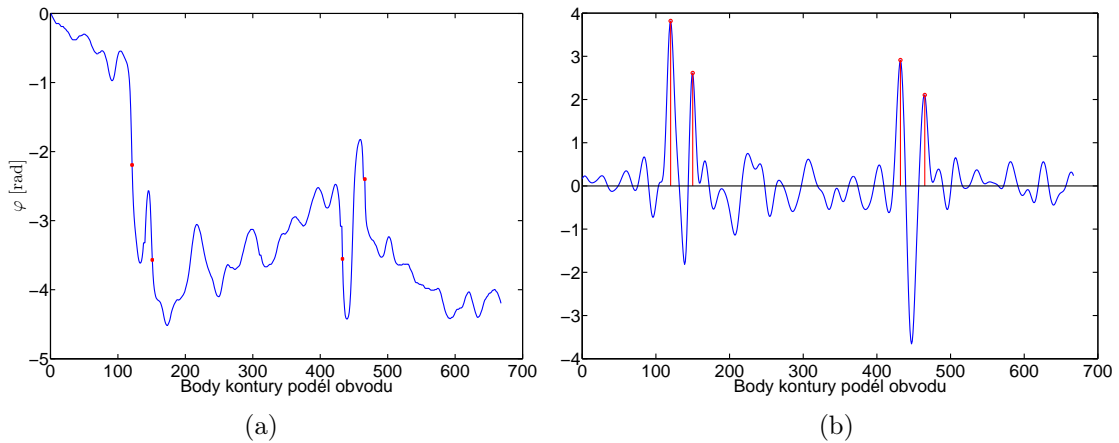
Obr. 5.6: Rekonstrukce funkce dle FDs: (a) pro  $K = 8$ ; (b) pro  $K = 16$ ; (c) pro  $K = 32$ .

## 5.6 Vlnkové deskriptory

Problém FDs, kvůli kterému je nelze použít, lze vyřešit aplikací WDs, které jsou obdrženy pomocí CWT dle vztahu (4.9). Na rozdíl od FT je zde zvolená báze funkce

nenulová pouze na konečném časovém intervalu, z tohoto důvodu WDs zachovávají informaci o pozici.

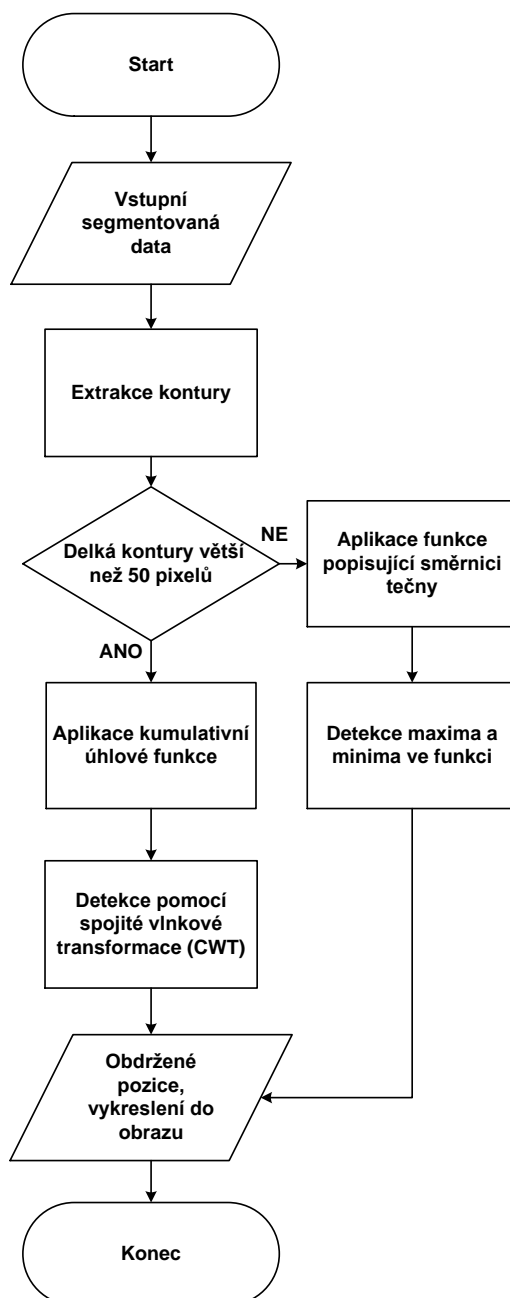
Obr. 5.7 demonstruje aplikaci WDs, kde jako vstupní signál ze kterého jsou vypočteny koeficienty CWT slouží kumulativní úhlová funkce. Červeně zakreslené body náležejí místům, kde vlivem segmentace došlo k přerušení kostní struktury. Lze vidět, že tyto body představují v kumulativní úhlové funkci vždy inflexní bod. Dle této apriorní znalosti je zvolena antisymetrická vlnka, která tyto body transformuje na extrémy. Konkrétní volba vhodné antisymetrické vlnky a také míra její dilatace (měřítko) bude vyžadovat rozsáhlé testování. Na zde přiložené ukázce je zvolena vlnka *bior1.5* s nastaveným měřítkem 15, kde lze vidět, že místa ve kterých došlo k přerušení segmentace, jsou transformována na signifikantní extrémy, jejichž následná detekce by představovala snadný úkol. Na základě tohoto faktu je tento typ deskriptoru využít pro detekci pozic chybně segmentovaných částí kostí, kde jako vstupní signál, pro výpočet koeficientů CWT, slouží kumulativní úhlová funkce.



Obr. 5.7: Deskriptor založený na CWT: (a) kumulativní úhlová funkce s vyznačenými body náležejícím chybně segmentovaným místům; (b) koeficienty CWT při zvolené vlnce *bior1.5* a nastaveném měřítku 15.


## 6 DETEKCE POTENCIÁLNĚ CHYBNĚ SEGMENTOVANÝCH ÚSEKŮ

V této kapitole bude podrobně popsán postup detekce pozic, ve kterých došlo vlivem segmentace k potenciálnímu přerušení kostí. Úplný postup detekce těchto pozic zná-



Obr. 6.1: Vývojový diagram detekce potenciálně chybně segmentovaných úseků.

zorní vývojový diagram na obr. 6.1, kde vstup představují segmentovaná data, na která je aplikována metoda extrakce kontury. Následně se testuje délka (počet pixelů) extrahované kontury. V případě, že délka je kratší než 50 pixelů (hodnota vychází z vizuálního pozorování kontur vyskytujících se v obrazech), jako tvarový deskriptor se aplikuje funkce popisující směrnicí tečny, kde jsou detekovány, pomocí maxima a minima ve funkci, pouze dva body lokalizující potenciální přerušení segmentace kosti. Dva body jsou detekovány z důvodu, že u tak malého objektu není předpokládáno přerušení kosti na více místech. Je také žádoucí zmínit, že tyto malé objekty bývají velmi často součástí kostí, které se vlivem segmentace přeruší (rozpadnou) na větší počet malých úseků. Tento případ demonstruje obr. 6.2. V opačném případě, kdy délka extrahované kontury je větší než 50 pixelů, aplikuje se kumulativní úhlová funkce, u níž jsou pomocí spojitě vlnkové transformace (CWT) lokalizovány náhlé změny, které odpovídají potenciálním místům přerušení kostních struktur. Výsledek poté představují pozice, kde došlo k potenciálnímu přerušení segmentovaných kostí, které je možné pro demonstraci zakreslit do segmentovaného obrazu.



Obr. 6.2: Přerušení (rozpadnutí) kosti vlivem segmentace: (vlevo) originální obraz; (uprostřed) segmentovaný obraz; (vpravo) detail vybrané oblasti, kde lze pozorovat výskyt většího počtu malých kostních objektů.

V následujících podkapitolách bude podrobně popsán postup detekce bodů jak u kumulativní úhlové funkce, tak u funkce popisující směrnicí tečny.

## 6.1 Detekce bodů u kumulativní úhlové funkce

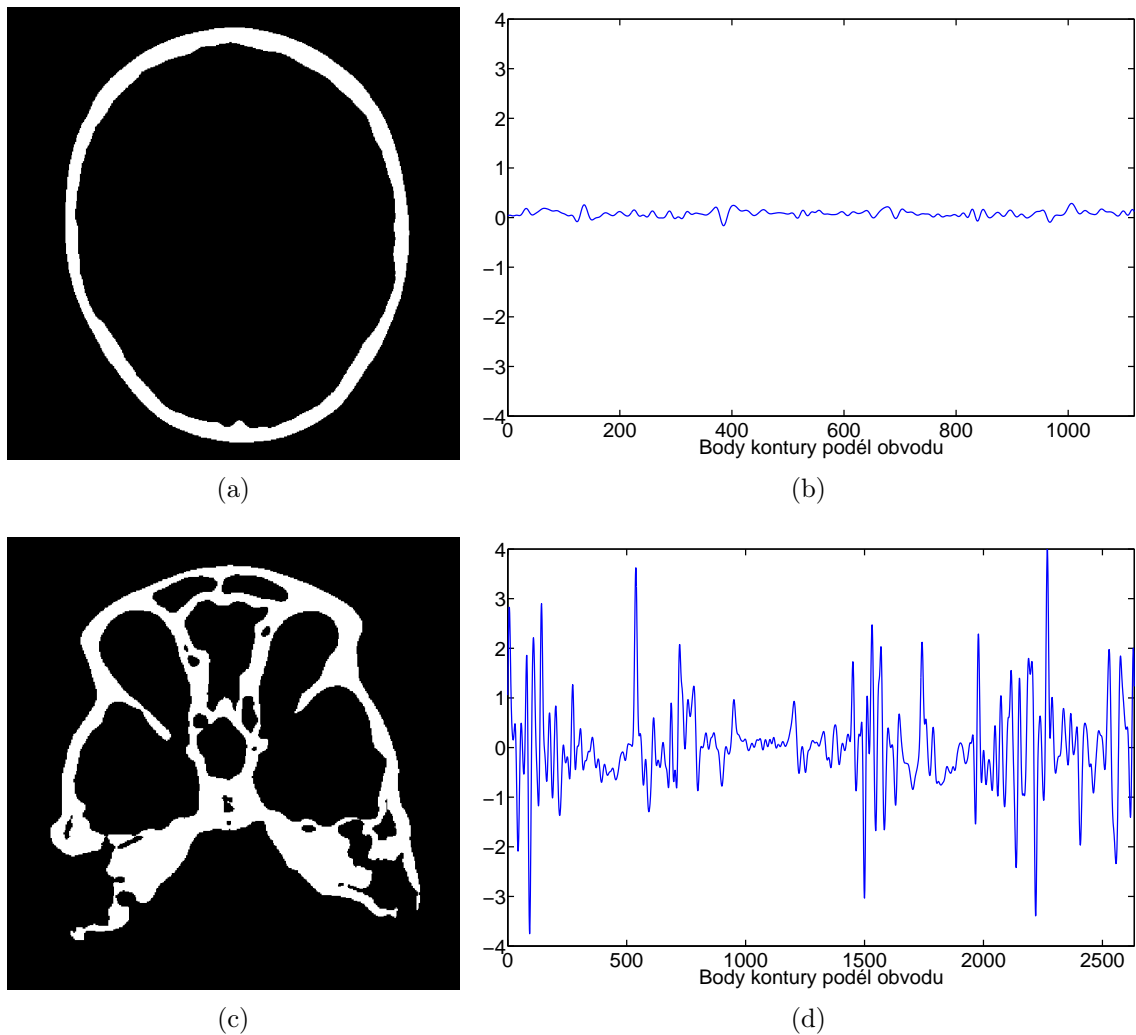
Jak již bylo řečeno výše, kumulativní úhlová funkce je aplikována pouze na extrahované kontury o délce větší než 50 pixelů. Obecně se ale v obrazu nacházejí i kontury, jejichž délka je větší než 2000 pixelů. Je proto nutné implementovat algoritmus, který v extrahované kontuře, resp. v obdržené funkci popisující daný tvar, detekuje potenciální místa přerušení segmentovaných kostí spolehlivě.

Potenciální místa chybné segmentace kostních struktur jsou reprezentovány náhlými změnami v kumulativní úhlové funkci. Pro detekci je využita CWT, kde při vhodně vybrané vlnce a nastaveném měřítku, lze s přesností tyto změny lokalizovat. Z důvodu výskytu okrajových jevů při CWT, je analyzovaná funkce prodloužena na obou koncích, opakováním prvního, resp. posledního vzorku, o pět procent délky funkce. Koeficienty CWT jsou poté vypočteny při nastavené vlnce *bior1.5* a měřítku 15. Důvod volby této vlnky<sup>1</sup> a především měřítka je empirický, neboť je prakticky nemožné s přesností určit frekvenční pásmo ve kterém se náhlé změny ve funkci nacházejí, jak je tomu např. u zpracování EKG signálu. Algoritmus byl proto testován s různým nastavením parametrů CWT a vybráno bylo to nastavení, které podávalo vizuálně nejlepší výsledky. Následně jsou eliminovány prodloužené části. Finální lokalizace pozic potenciálně chybně segmentovaných úseků poté spočívá v detekci kladných nadprahových extrémů, kde práh je stanoven empiricky jako 1,6 násobek směrodatné odchylky koeficientů CWT. Záporné extrémy se neuvažují, neboť jejich pozice odpovídají vždy místům v konvexních částech kontury, což jsou místa představující náhlou změnu v kumulativní úhlové funkci, ale zároveň místa, kde k přerušení segmentovaných kostí nedošlo. Je nutno podotknout, že před samotným algoritmem detekce extrémů je vypočtena hodnota rozptylu koeficientů CWT. V případě, že rozptyl koeficientů je velmi malý (v programu empiricky nastaveno jako menší než 0,15), tak se detekce extrémů neuskuteční a objekt je vyhodnocen jako správně segmentovaný. V opačném případě, když rozptyl koeficientů CWT nabývá hodnoty větší než 0,15, se detekce extrémů dle popsaného algoritmu provede. Toto ošetření je z důvodu výskytu kontur nevykazujících prakticky žádnou členitost (např. kontura kruhovitěho tvaru), u kterých není předpokládán výskyt přerušení segmentace kostí. Pro názorný příklad uveďme, že se jedná především o kontury vyskytující se v posledních řezech objemu dat (kruhovitá kontura lebky). Vliv členitosti kontury na rozptyl koeficientů CWT demonstruje obr. 6.3.

Na obr. 6.4 je demonstrován výsledek detekce potenciálně chybně segmentovaných kostí s využitím kumulativní úhlové funkce a CWT. Výsledek je demonstrován na dvou binárních objektech (obr. 6.4 vlevo) získaných implementovanou segmentací, přičemž horní řada reprezentuje postup detekce pro první binární objekt a spodní

---

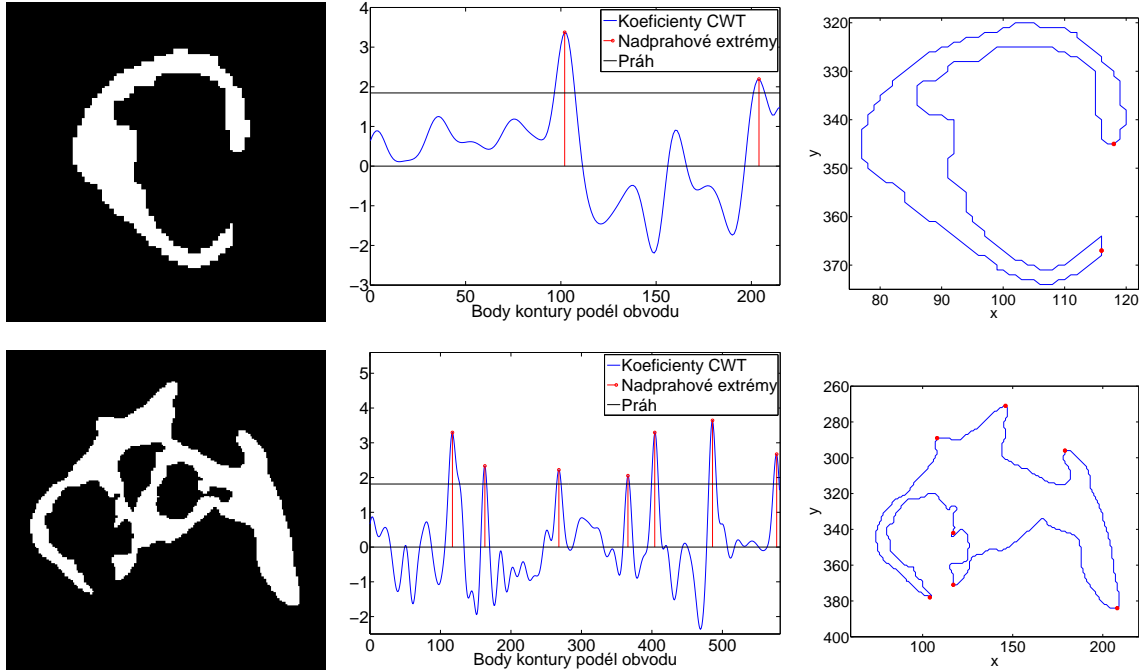
<sup>1</sup>Byly testovány pouze antisymetrické vlnky, důvod je popsán v kapitole 5.6.



Obr. 6.3: Ukázka vlivu členitosti kontury na rozptyl koeficientů CWT: (a,c) binární region reprezentující segmentovanou kost; (b) obdržené koeficienty CWT pro analyzovanou konturu z regionu (a), kde rozptyl koeficientů je 0,0040; (d) obdržené koeficienty CWT pro analyzovanou konturu z regionu (c), kde rozptyl koeficientů je 0,7092.

řada pro druhý. U prvního objektu je potenciální přerušení segmentace kosti reprezentováno dvěma body, přesněji se jedná o rohové výběžky na pravé straně objektu. Druhý objekt vykazuje velkou členitost a místa, kde došlo k potenciálnímu přerušení segmentace kosti, představují vyskytující se rohové a špičaté útvary, ve kterých lze sledovat prudkou změnu směru hrany regionu. Z těchto objektů je následně extrahována kontura, vypočtena kumulativní úhlová funkce a poté koeficienty CWT (obr. 6.4 uprostřed), kde jsou detekovány nadprahové extrémny, jejichž pozice jsou pro názornost zakresleny do extrahované kontury analyzovaného objektu (obr. 6.4 vpravo). Lze vidět, že u prvního objektu byly pomocí uvedeného algoritmu detekovány dva

extrémy, jejichž pozice po zakreslení do extrahované kontury odpovídají přesně místům, kde došlo k potenciálnímu přerušení segmentace kosti. U druhého objektu bylo detekováno celkem sedm extrémů, jejichž pozice skutečně odpovídají místům vykazujícím velkou členitost a tudíž místům, kde potenciálně došlo k přerušení kosti.



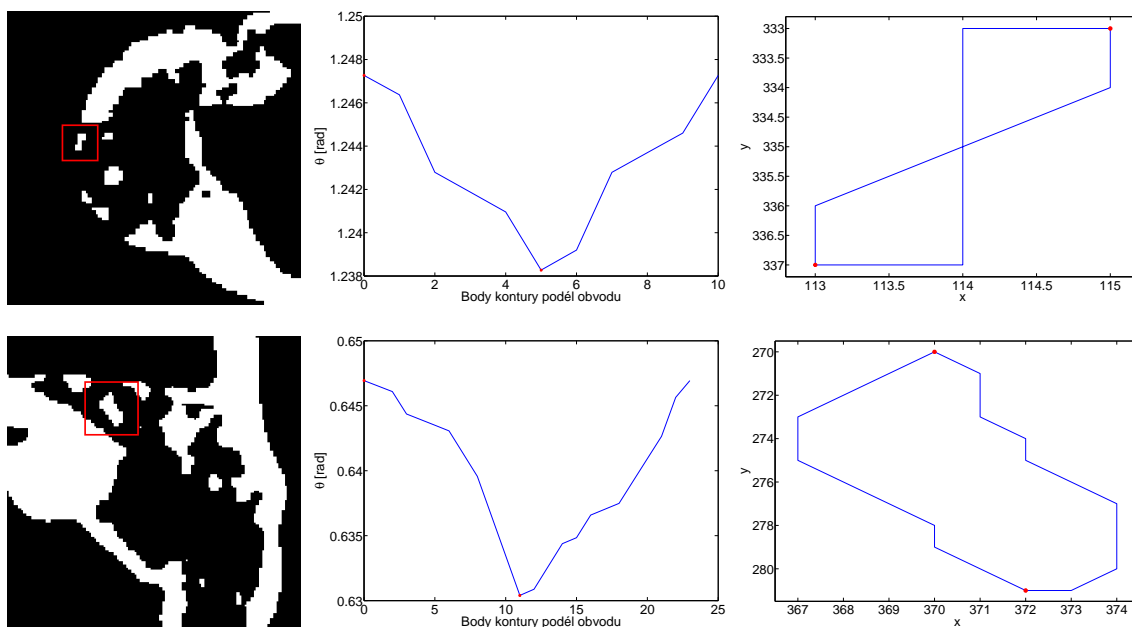
Obr. 6.4: Detekce pozic potenciálně chybně segmentovaných úseků s využitím CWT: (vlevo) binární region reprezentující segmentovanou kost; (uprostřed) obdržené koeficienty CWT s detekovanými nadprahovými extrémami; (vpravo) zakreslení detekovaných pozic do kontury analyzovaného regionu.

## 6.2 Detekce bodů u funkce popisující směrnicí tečny

Funkce popisující směrnicí tečny je aplikována pouze na kontury, jejichž délka není vyšší než 50 pixelů. U takovýchto kontur není předpokládán výskyt více než dvou míst, kde by mohlo dojít k přerušení segmentace kosti, neboť se jedná vždy o velmi drobné kostní útvary (mnohdy i izolované pixely). Z tohoto důvodu je předpokládáno, že k potenciálnímu přerušení došlo vždy na protilehlých hranách, kolmých na delší osu, analyzovaného objektu. Zmíněnou úvahu dokazuje obr. 6.2.

V analyzované funkci je sledována náhlá změna v úhlu popisujícího směrnicí tečny. Tato změna odpovídá rohovitému místu kontury neboli místu, kde kontura razantně mění svůj směr. V praxi se tedy vždy ve funkci vyskytují dvě náhlé změny,

které přesně odpovídají protilehlým hranám analyzovaného objektu. Na obr. 6.5 vlevo lze vidět dvě vybrané oblasti, kde došlo vlivem segmentace k přerušení (rozpadu) kostí na větší množství velmi malých regionů. Červená oblast zde ohraničuje jeden malý region, na kterém je demonstrován výsledek algoritmu detekce potenciálně přerušených kostí. Z těchto regionů, resp. z jejich extrahovaných kontur je vypočtena funkce popisující směrnicí tečny (obr. 6.5 uprostřed), kde lze vidět, že lokalizace náhlých změn je zde velmi jednoduchá úloha neboť tyto dvě změny vždy představují maximum, resp. minimum v analyzované funkci. Je tedy dostačující detekovat pozice maxima a minima vyskytujícího se ve funkci (detekované body jsou zakresleny ve funkci červeně), kde tyto pozice přesně odpovídají hledaným místům potenciálně přerušené segmentace což dokazuje obr. 6.5 vpravo, kde jsou detekované pozice červeně zakresleny do extrahované kontury analyzovaného regionu.



Obr. 6.5: Detekce pozic potenciálně chybně segmentovaných úseků u funkce popisující směrnicí tečny: (vlevo) výřez segmentovaného obrazu s vyznačeným regionem na kterém je demonstrován algoritmus; (uprostřed) obdržená funkce popisující směrnicí tečny se zakreslenými detekovanými body; (vpravo) zakreslení detekovaných pozic do kontury analyzovaného regionu.



## 7 VÝSLEDKY DETEKCE A MOŽNOSTI VYUŽITÍ


Výstup implementovaného algoritmu, popsaného v předchozí kapitole, je představován nalezenými pozičními souřadnicemi potenciálně chybně segmentovaných kortikálních částí kostí. Zde budou demonstrovány výsledky detekce pomocí zakreslení obdržených pozic do segmentovaného obrazu. Bude provedena diskuze kvality této detekce a objasněny případy, kde algoritmus funguje spolehlivě a ve kterých situacích selhává. Následně budou popsány možnosti dalšího využití znalosti pozičních souřadnic, ve kterých došlo k potenciálnímu přerušení segmentovaných kostí. Využití bude především zaměřeno na klasifikaci, které z detekovaných pozic skutečně náleží místům přerušení segmentace kostí a také budou diskutovány možnosti doplnění přerušených kortikálních částí kostí.

### 7.1 Výsledky detekce potenciálně chybně segmentovaných úseků

Jak již bylo řečeno v kapitole 3.3, segmentace kostních struktur ze snímků hlavy bývá nejkomplikovanější v oblasti spodiny lebeční. Výsledky implementovaného algoritmu budou tedy demonstrovány na segmentovaných snímcích z této oblasti hlavy.

Na obr. 7.1 lze vidět praktickou ukázkou dosažených výsledků detekce potenciálně chybně segmentovaných úseků. Pro názornost je binární maska získána segmentací násobena s původním obrazem (obr. A.1a). Červeně zakreslené body v obrazu představují detekované místa, kde došlo k potenciálnímu přerušení segmentovaných kostí. Dle celkového obrazu, i přiloženého detailu vybrané oblasti, lze intuitivně pozorovat, že detekce proběhla úspěšně. Je ale potřeba zmínit, že správnost detekce je zde obtížné vyhodnotit, neboť není k dispozici standard pro porovnání výsledků dosažené segmentace. Vybraný detail reprezentuje výsledek segmentace v oblasti spánkové kosti, která zde představuje velmi tenkou kortikální kost, což má často za následek podprahovou hodnotu intenzity některých částí tohoto objektu. Důsledkem jsou poté přerušené části kosti po aplikaci implementované metody segmentace. Dle červeně zakreslených bodů v detailu vybrané oblasti, lze konstatovat, že implementovaný algoritmus dokázal lokalizovat relativně přesně pozice, kde došlo k přerušení segmentace kosti. Při pohledu na výsledek spánkové kosti na opačné straně hlavy je zřejmé, že zde došlo také k přerušení velmi tenkých kortikálních částí. I zde algoritmus lokalizoval přesné pozice, kde nastalo přerušení segmentace kosti. Je vhodné podotknout, že ve snímcích, které těsně předcházejí a také těsně následují za demon-


stračním snímkem ve sledovaném objemu dat, jsou rovněž detekovány stejné pozice, ve kterých došlo k přerušení segmentace kosti.



Obr. 7.1: Detekce úseků chybně segmentované spánkové kosti: (a) obraz reprezentující segmentovanou kosti se zakreslenými pozicemi, které algoritmus vyhodnotil jako potenciální místa přerušení segmentace kosti; (b) detail oblasti spánkové kosti pro názornější vizuální kontrolu.

Další příklad ukázky dosažených výsledků detekce potenciálně chybně segmentovaných kostí demonstruje obr. 7.2. Originální obraz lze vidět na obr. A.1b. V tomto případě detail vybrané oblasti reprezentuje segmentaci nosních kůstek, které jsou obdobně jako spánková kost představovány velmi drobnými a tenkými kortikálními kostmi, což má naprosto stejný důsledek (přerušené části kostí po aplikaci implementované metody segmentace). Na přiloženém detailu oblasti lze vidět, že detekce bodů, kde došlo k přerušení kostí, proběhla úspěšně. Jsou lokalizovány veškeré koncové body přerušovaných segmentovaných objektů. I zde platí, že ve snímcích, které těsně předcházejí a těsně následují demonstrováný snímek, jsou detekovány pozice potenciálních míst přerušení segmentace kosti, které spolu souvisejí.

Doposud byly představeny výsledky na kterých implementovaný algoritmus dokázal spolehlivě detekovat pozice, kde došlo k přerušení segmentace kostních struktur. Je ale nutno zmínit, že jsou situace ve kterých algoritmus selhává. Tyto situace budou demonstrovány za pomoci obr. 7.3a. Jedná se také o řez z oblasti spodiny lebeční a i zde je binární maska získána segmentací pro názornost násobená s původním obrazem (obr. A.1c). Červeně zakreslené body představují místa, která algoritmus vyhodnotil jako potenciálně přerušované segmentované kosti. Obecně mohou




Obr. 7.2: Ukázka detekce úseků chybně segmentovaných nosních kůstek: (a) obraz reprezentující segmentované kosti se zakreslenými pozicemi, které algoritmus vyhodnotil jako potenciální místa přerušení segmentace kosti; (b) detail oblasti nosních kůstek pro názornější vizuální kontrolu.

nastat celkem tři situace, ve kterých algoritmus selhává. Nyní bude věnován prostor pro objasnění těchto situací.

První situaci, která může nastat, demonstruje obr. 7.3b, který reprezentuje detail červené oblasti vybrané z celkového segmentovaného obrazu. Zde lze vidět, že algoritmus vyhodnotil vyskytující se rohové výběžky jako místo, kde došlo k přerušení kosti. Ale při pouhém vizuálním pohledu je patrné, že zde byla segmentace této lebeční kosti správná. Nedošlo k žádnému přerušení, které by bylo potřebné lokalizovat. Důvod proč algoritmus tyto pozice vyhodnotil jako místa přerušení je zřejmý: tyto rohové výběžky analyzované kontury představují velkou náhlou změnu v odpovídající kumulativní úhlové funkci. Algoritmus poté, vzhledem k absenci apriorní znalosti, nedokáže rozeznat jestli se opravdu jedná o správnou segmentaci nebo došlo k přerušení. Tyto pozice tedy bude brát jako místo, kde došlo k potenciálnímu místu přerušení. Je potřeba dodat, že takovýchto detekovaných pozic se vždy v obrazu nalézají více, přičemž následným zpracováním, popsáním v kapitole 7.2, lze tyto detekované pozice eliminovat.

Druhá situace, kdy algoritmus selhává je zobrazena na obr. 7.3c, který reprezentuje detail zelené oblasti vybrané z celkového segmentovaného obrazu. Zde lze pozorovat, že algoritmus detekoval v rohovém výběžku dva body těsně vedle sebe, kde došlo k potenciálnímu přerušení kosti. To je zapříčiněno výskytem dvou nadpra-

hových extrémů, v obdržených koeficientech CWT, velmi blízko sebe. Jsou tedy následně detekovány dvě takřka totožné pozice, místo pouze jedné. Avšak i tyto falešně detekované pozice nepředstavují závažný problém, jelikož je následným zpracováním lze rovněž potlačit.



Obr. 7.3: Ukázka situací kdy implementovaný algoritmus selhává: (a) obraz reprezentující segmentované kosti se zakreslenými detekovanými pozicemi, kde potenciálně došlo k přerušení segmentace kostí; (b) detail červené oblasti znázorňující falešnou detekci; (c) detail zelené oblasti znázorňující detekci dvou takřka stejných pozic; (d) detail modré oblasti znázorňující potenciálně přerušenu kost, kterou algoritmus nedokázal detekovat.

Poslední, třetí situaci selhání implementovaného algoritmu demonstruje obr. 7.3d, který reprezentuje detail modré oblasti vybrané z celkového segmentovaného obrazu. Tato situace představuje největší problém ze všech tří diskutovaných, neboť jak lze vidět na přiloženém detailu, algoritmus nedokázal detekovat místo, kde došlo k potenciálnímu přerušení kosti. Jedná se o problém, který prakticky nelze následným zpracováním vyřešit. Výskyt této situace je způsoben faktem, že analyzovaná kumulativní úhlová funkce sice obsahuje náhlou změnu odpovídající této pozici, ale její frekvenční pásmo spadá mimo pásmo, které zdůrazňuje CWT s danou vlnkou a dilatací. Tato náhlá změna se tudíž transformuje jako podprahový extrém, který implementovaný algoritmus nepovažuje za místo, kde mohlo dojít k potenciálnímu přerušení segmentace kosti. Je vhodné podotknout, že frekvence výskytu této a také jmenované druhé situace, kdy algoritmus selhává, je napříč analyzovaným objemem dat velmi nízká, což plyne z intuitivního pozorování dosažených výsledků.

Více ukázek detekce chybně segmentovaných (přerušených) úseků kostí demonstruje obr. B.1.

## 7.2 Možnosti využití znalosti pozic detekovaných úseků

Lokalizované poziční souřadnice, ve kterých došlo k potenciálnímu přerušení segmentace kortikálních částí kostí, mohou sloužit jako velmi cenná informace, kterou lze využít jako apriorní znalost pro následné zlepšení a zpřesnění výsledné segmentace kostních struktur. Připomeňme, že implementovaná metoda segmentace kostních struktur (prosté prahování s globálním prahem) dokáže segmentovat spolehlivě pouze kosti, jejichž intenzita se nepřekrývá s intenzitami náležícími měkkým tkáním. Tuto podmínku splňují především kortikální části kostí. Trabekulární části, jak již bylo zmíněno výše, zanechávají v segmentovaném obrazu díry, což jsou oblasti nulové intenzity, které jsou plně ohraničeny kortikální kostí (demonstruje obr. 3.6). Následně bude popsána možnost využití lokalizovaných pozic pro vylepšení úspěšnosti klasifikace trabekulárních částí kostí a bude také demonstrována implementovaná metoda doplnění přerušených kortikálních částí kostí.

### 7.2.1 Klasifikace trabekulárních částí kostí

Při požadavku správné segmentace trabekulárních částí kostí je možno postupovat dle algoritmu publikovaném v [25], kde vzniklé díry lze pomocí techniky sledování hranic (*angl.* boundary tracking technique) separovat. Poté následuje klasifikace zda konkrétně testovaná díra reprezentuje měkkou tkáň nebo trabekulární kost. Jako

vektor příznaků pro rozhodnutí slouží pět parametrů (kompaktnost, šikmost, špičatost, entropie a relativní pozice průměrné hodnoty histogramu vzhledem k pozici píku reprezentujícímu rozložení měkkých tkání v histogramu celého objemu dat) zjištěných z vypočteného lokálního histogramu, neboť typický histogram reprezentující rozložení intenzit měkkých tkání se liší svým tvarem od typického histogramu reprezentujícího rozložení intenzit trabekulárních kostí. Samotná klasifikace je poté provedena pomocí neuronové sítě.

Tato metoda klasifikace trabekulárních částí kostí funguje úspěšně pouze u trabekulárních částí, které jsou plně (nepřerušeně) obklopeny kortikální částí kosti a pomocí metody sledování hranic je lze separovat. Jak ale bylo poukázáno výše, v obrazu se nacházejí i velmi tenké kortikální kosti, které nevykazují nadprahovou intenzitu a tudíž jsou segmentovány nesprávně, což má za následek přerušeni kosti, a to vede k neúplnému (přerušnému) obklopení trabekulární kosti. Dle tohoto faktu poté technika sledování hranic nedokáže ze segmentovaného obrazu separovat díru, což má za následek chybnou segmentaci konkrétní trabekulární kosti.

V případě, že budou známy pozice, ve kterých došlo k potenciálnímu přerušeni kortikálních kostí, lze klasifikaci trabekulárních částí kostí dodatečně vylepšit. Lokalizované poziční souřadnice by vstupovaly do procesu klasifikace trabekulárních částí kostí jako apriorní znalost, přičemž by bylo nutné implementovat vhodný algoritmus, který zajistí separování děr i v případě, že nejsou zcela ohraničeny kortikální kostí. K tomuto účelu by znalost pozičních souřadnic, reprezentujících potenciální místa přerušeni kortikální kosti, byla klíčovou informací, pomocí níž by tento úkol bylo možné realizovat. Následně by se postupovalo jak je popsáno výše. Vypočetl by se lokální histogram obrazu pro oblast separované díry, na jehož základě (resp. zjištěných příznaků) by se konkrétně analyzovaná díra klasifikovala jako měkká tkáň nebo trabekulární kost. Zde lze využít apriorní znalosti, že v případě kdy bude separovaná díra klasifikována jako trabekulární kost, tak z anatomického hlediska musí být ohraničena kortikální kostí. Na základě tohoto faktu lze považovat odpovídající (které byly pro separaci díry využity) poziční souřadnice potenciálně chybně segmentované kosti jako správné. V opačném případě, kdy bude separovaná díra klasifikována jako měkká tkáň, tak se odpovídající detekované poziční souřadnice uvažovat nebudou. Tímto by byly eliminovány prakticky veškeré falešně detekované pozice chybně segmentovaných kortikálních částí kostí. Konečná úprava by představovala doplnění chybně segmentovaných úseků vhodnou metodou.

Výstup objasněné techniky by poté s velkou pravděpodobností představoval velmi přesně segmentovaný obraz kostních struktur. Je možné zmínit, že následnou subtrakcí (odečtením) segmentovaného obrazu od obrazu originálního, by byl získán, rovněž velmi přesně, segmentovaný obraz reprezentující měkké tkáně.

## 7.2.2 Možnosti doplnění přerušovaných kortikálních částí kostí

Zde bude popsána implementovaná metoda doplňující chybně segmentované úseky kostí, které byly zjištěny výše zmíněným algoritmem. Je nutno zmínit, že metoda je vyvinuta čistě pro testovací účely a k demonstraci možného postupu při doplnění chybně segmentovaných úseků. Slouží také pro objasnění veškerých úskalí, která jsou s tímto problémem spojeny.

Technika je založena na segmentační metodě narůstání oblasti (*angl.* region growing), kde vstup představuje vždy originální obraz, globální práh pro segmentaci kortikálních částí kostí (viz kapitola 3.3) a poziční souřadnice ve kterých došlo k potenciálnímu přerušování segmentovaných kostí. V prvním kroku se v cyklu porovnávají všechny možné dvojice pozičních souřadnic, přičemž je vždy vypočtena jejich Euklidovská vzdálenost  $d$  dle vztahu

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}, \quad (7.1)$$


kde  $(x_1, y_1)$  jsou souřadnice prvního potenciálního bodu přerušování a  $(x_2, y_2)$  druhého. Následuje testování podmínky zda vypočtená vzdálenost dvou uvažovaných potenciálních bodů přerušování je menší nebo rovna empiricky, na základě faktu, že většina částí skutečně přerušovaných kostí je blízko sebe, stanovené hodnotě 20 pixelů. Pokud konkrétní uvažované dva body tuto podmínku splňují, bude tento úsek přerušování doplněn. Tímto je zabezpečeno, že implementovaná metoda nebude aplikována mezi body přerušování, které leží např. na protilehlých stranách obrazu. V dalším kroku je získána binární maska, která nabývá jednotkové hodnoty pouze v oblasti zájmu, kde se má implementovaná metoda aplikovat. Oblast zájmu zde představuje pravouhlá oblast, v matici originálního obrazu, vymezená dle pozičních souřadnic uvažovaných dvou bodů. Jinými slovy tyto dva body náležejí protilehlým rohům vymezené oblasti zájmu. Nakonec je vymezená oblast ve všech čtyřech směrech zvětšena o 5 pixelů, což je aplikováno z důvodu, že doplněný úsek nemusí, mezi uvažovanými body, představovat vždy spojnici, ale jeho tvar může vykazovat různý stupeň zakřivení, což by velikost předchozí oblasti nezohledňovala. Takto získanou maskou je vynásoben vstupní obraz. Poté následuje aplikace metody narůstání oblasti, kde jako počáteční semínko je vybrán pixel na pozičních souřadnicích prvního z uvažovaných potenciálních bodů přerušování segmentace kortikální části kosti. Narůstání oblasti je založeno na testování čtyř okolí pixelu, kde výsledné přiřazení právě testovaného pixelu  $p$  ke kortikální kosti nebo měkké tkáni definuje vztah

$$|t - I(p)| = \begin{cases} \leq \alpha & \Rightarrow \text{přiřazeno ke kosti} \\ > \alpha & \Rightarrow \text{přiřazeno k měkké tkáni} \end{cases}, \quad (7.2)$$

kde  $t$  je globální práh pro segmentaci kortikálních částí kostí,  $I(p)$  značí intenzitu

právě testovaného pixelu  $p$  a parametr  $\alpha$  je statické kritérium, v programu nastaveno na hodnotu 0,03. Pokud je testovaný sousední pixel přiřazen ke kosti, stává se novým semínkem a proces se opakuje. Zastavení narůstání nastane v případě, že nebude žádný sousední pixel všech semínek splňovat kritérium dle vztahu (7.2) nebo pokud bude vyplněná celá uvažovaná oblast zájmu definovaná maskou. Výsledek poté představuje doplněnou kortikální kost, která byla vlivem segmentace přerušena.

Na obr. 7.4 lze vidět výsledek implementované metody, kde obr. 7.4a reprezentuje originální obraz s vybranou oblastí na které je metoda demonstrována. Obr. 7.4b je poté segmentovaný detail vybrané oblasti originálního obrazu, kde červeně jsou zakresleny detekované potenciálně chybně segmentované úseky kostí. Finální výsledek, po aplikaci implementované metody doplňující chybně segmentované úseky, demonstruje obr. 7.4c. Lze intuitivně pozorovat, že výsledek doplnění je relativně přesný, neboť detekované poziční souřadnice opravdu odpovídaly místům, kde došlo k přerušení kortikální části kosti. Z tohoto důvodu implementovaný algoritmus dokázal segmentovat chybějící úsek přerušené kortikální kosti.




Obr. 7.4: Ukázka metody doplnění chybně segmentovaných úseků pro případ správně detekovaných bodů: (a) originální obraz; (b) segmentovaný detail zakreslené oblasti originálního obrazu s detekovanými pozicemi potenciálně chybně segmentovaných částí kosti; (c) výsledek doplnění přerušného úseku.

Jak již bylo řečeno, v obrazu je vždy detekováno určité množství pozičních souřadnic, které nenáleží bodům, kde došlo k přerušení kortikální kosti. Jedná se např. o zmíněnou výduť v kosti, kterou vyplňuje měkká tkáň apod. V takovémto případě implementovaná metoda doplnění přerušných úseků selhává. Obr. 7.5 demonstruje situaci selhání implementované metody, kde na obr. 7.5a lze vidět originální obraz a na obr. 7.5b segmentovaný detail vybrané oblasti originálního obrazu, přičemž červeně jsou zakresleny detekované potenciálně chybně segmentované úseky kostí.



Nakonec obr. 7.5c reprezentuje výsledek implementované metody. Dle vizuálního pozorování lze vidět, že úsek mezi falešně detekovanými pozicemi (zde se konkrétně jedná o výduť v kosti, která je vyplněná měkkou tkání) metoda chybně doplnila a navíc se při samotném průběhu segmentovaný úsek rozrostl do stran. Lze si všimnout, že segmentovaný úsek vyplňuje prakticky celou oblast definovanou binární maskou získanou v předcházejícím kroku. Druhá situace, při které implementovaná metoda selhává, nastane v případě kdy vypočtená vzdálenost dvou uvažovaných potenciálních bodů přerušení je větší než 20 pixelů a přitom se jedná o správně detekované body, kde opravdu došlo k přerušení segmentace kortikální kosti. V tomto případě vůbec neproběhne algoritmus doplnění a analyzovaná kost zůstane přerušena.



Obr. 7.5: Ukázka metody doplnění chybně segmentovaných úseků pro případ falešně detekovaných bodů: (a) originální obraz; (b) segmentovaný detail zakreslené oblasti originálního obrazu s detekovanými pozicemi potenciálně chybně segmentovaných částí kosti; (c) výsledek doplnění přerušného úseku.

Ještě jednou připomeňme, že popsaná metoda pro doplnění přerušovaných úseků kortikálních částí kostí slouží pouze pro demonstrační účel a jako možnost budoucího směru vývoje algoritmu pro segmentaci kostí v CT datech. Její úskalí, díky němuž je v této fázi prakticky nepoužitelná, spočívá ve výskytu pouze potenciálních pozic ve kterých došlo k přerušení segmentace kortikálních částí kostí. Pro správnou funkčnost je zapotřebí znát pouze pozice ve kterých opravdu došlo k přerušení, což by bylo možné s využitím postupu popsaném v kapitole 7.2.1. V opačném případě výsledek algoritmu dopadne obdobně jako na přiloženém obr. 7.5c, což je pro finální výstup metody segmentace kostí nepřijatelné.

## 8 ZÁVĚR

Cílem práce bylo provést rešerši publikovaných metod a algoritmů pro segmentaci kostních struktur v objemových CT datech. Následně byla implementována segmentace kortikálních částí kostí metodou prostého prahování s globálním prahem. Práh je určen dle detekce pozice signifikantního píku reprezentujícího rozložení měkkých tkání v histogramu celého objemu dat a jeho následným optimalizovaným proložením vybraným typem pravděpodobnostního rozdělení. Konkrétně se jedná o normální (Gaussovo) nebo Pearsonovo rozdělení typu VII, které především díky parametru ovlivňujícího špičatost, aproximuje rozložení měkkých tkání přesněji. Pro optimalizaci výchozího rozdělení byly implementovány tři optimalizační algoritmy: úplné prohledávání, náhodné prohledávání nebo metoda nejmenších čtverců. Dle dosažených výsledků lze vidět, že segmentace kortikálních částí kostí je úspěšná až na drobné kostní útvary nebo kosti s velmi tenkou kortikální částí, díky čemuž lze poté v obrazu nalézt nedokonale segmentované (přerušené) kostní struktury.

Poté jsou rozebrány možnosti, kterými lze kvantitativně popisovat tvary objektů v obrazu, přičemž důraz je kladen na reprezentaci tvaru na základě kontur a především na tvarové deskriptory, které mohou být užitečné pro detekci nedostatečně segmentovaných kortikálních částí kostí. Následně jsou implementovány vybrané tvarové deskriptory a na reálných příkladech je demonstrováno jejich možné využití pro následnou detekci chybně segmentovaných kortikálních částí kostí. Lze vidět, že funkce vzdálenosti od těžiště objektu je prakticky nepoužitelná, neboť nelze z jejího průběhu spolehlivě detekovat zájmové body představující pozice chybně segmentovaných míst. Naopak kumulativní úhlová funkce se jeví jako velmi užitečná alternativa, neboť ve funkci obsažené náhlé změny, resp. inflexní body, reprezentují místa v analyzované kontuře, kde došlo k prudkým změnám sledovaného úhlu. Dle tohoto faktu dokáže funkce spolehlivě zaznamenat členité útvary kontury, kterými jsou často místa, kde došlo k přerušení segmentace kosti, reprezentována. Z důvodu výskytu i velmi malých objektů vzniklých při segmentaci, na které nelze aplikovat kumulativní úhlovou funkci (z důvodu nutnosti výpočtu diferencí), je aplikována funkce popisující směrnici tečny, která v případě takto malých objektů dokáže lokalizovat místa ve kterých došlo k potenciálnímu přerušení segmentace kosti. Také jsou demonstrovány FDs, které i přes jednoduchou implementaci, robustnost a dobrou diskriminační schopnost, nejsou pro tento typ aplikace vhodným řešením neboť vlivem FT zcela postrádají prostorové rozlišení. Tento problém lze ale vyřešit použitím WDs založených na WT, kde při uvažování kumulativní úhlové funkce jako vstupního signálu, lze relativně přesně a spolehlivě detekovat místa, kde došlo k potenciálnímu přerušení segmentace kostí.

V další části je podrobně objasněn postup detekce potenciálně chybně segmen-

tovaných úseků kortikálních částí kostí, kde je využita zmíněná kumulativní úhlová funkce, u které jsou pozice detekovány pomocí CWT, a funkce popisující směrnicí tečny, u které jsou pozice detekovány pomocí nalezení maxima a minima ve funkci. Následně je na přiložených výsledcích demonstrována a diskutována úspěšnost implementovaného algoritmu, spolu se situacemi, ve kterých algoritmus selhává. Dle dosažených výsledků lze konstatovat, že implementovaný algoritmus funguje přesně a dokáže takřka spolehlivě lokalizovat potenciální místa přerušení segmentovaných kortikálních částí kostí.

Na závěr jsou diskutovány možnosti využití znalosti potenciálních pozic přerušení. Především jako apriorní znalost pro klasifikaci trabekulárních částí kostí, je tato informace stěžejní, neboť dle popsaného postupu bylo bez znalosti pozic, ve kterých došlo k potenciálnímu přerušení segmentace kortikálních částí kostí, nemožné separovat díry (reprezentující chybně segmentované trabekulární částí kostí), které nebyly zcela uzavřeny kortikální kostí. Výstup této techniky by poté s velkou pravděpodobností představoval velmi přesně segmentovaný obraz kostních struktur, který by bylo možné porovnat s již existujícími metodami sloužícími k segmentaci kostních struktur v CT datech. Je také demonstrován implementovaný algoritmus pro doplnění chybně segmentovaných úseků kostí, který je založen na metodě narůstání oblasti. Je nutno zmínit, že algoritmus slouží pouze pro testovací účely a vhodnost jeho použití je diskutována v náležité kapitole.

Program byl implementován v prostředí MATLAB<sup>®</sup> a testován na PC s procesorem Intel Core 2 Duo 2,10 GHz a 4 GB RAM pamětí. Přičemž výpočetní náročnost segmentace je průměrně 11s na celý objem dat. U detekce chybně segmentovaných úseků je výpočetní čas menší než 1s/řez. Celkově se tedy jedná o velmi efektivní metodu.

## LITERATURA

- [1] BELONGIE, S., MALIK, J. a PUZICHA, J. *Matching Shapes*. Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001, č. 1, s. 133-146.
- [2] BERGER, J. O. *Statistical Decision Theory and Bayesian Analysis*. 2nd ed. New York: Springer-Verlag, 1993, xvi, 617 p. ISBN 03-879-6098-8.
- [3] COCKCROFT, J. K., BARNES, P. *Course Material: Peak Shapes* [online]. Birkbeck College, University of London, 2006. [cit. 24. 11. 2013]. Dostupné z URL: <<http://pd.chem.ucl.ac.uk/pdmn/peaks/peakindx.htm>>.
- [4] COSTA, L. F., CESAR JR., R. M. *Shape Analysis and Classification: Theory and Practise*. FL: CRC Press, 2001, 659 p. ISBN 08-493-3493-4.
- [5] DRASTICH, A. *Tomografické zobrazovací systémy*. 1. vyd. Brno: VUT, 2004, 208 s. ISBN 80-214-2788-4.
- [6] FAJMON, B., RŮŽIČKOVÁ, I. *Matematika 3*. 1. vyd. Brno: VUT, 2004, 257 s.
- [7] FISHER, R. A. *Accuracy of observation, A mathematical examination of the methods of determining, by the mean error and by the mean square error*. Monthly Notices of the Royal Astronomical Society. 1920, vol. 80, p. 758-770.
- [8] FREEMAN, H. *On the encoding of arbitrary geometric configurations*. IEEE Transactions on Electronic Computers. 1961, EC-10, issue 2, s. 260-268.
- [9] HALL, M. M., VEERARAGHAVAN. V. G., RUBIN. H. a WINCHELL, P. G. *The approximation of symmetric X-ray peaks by Pearson type VII distributions*. Journal of Applied Crystallography. 1977, vol. 10, issue 1, s. 66-68.
- [10] HOUNDSFIELD, G. N. *Computerized transverse axial scanning (tomography): Part I. Description of system*. The British Journal of Radiology. 1973, vol. 46, issue 552, s. 1016-1022.
- [11] JAN, J. *Číslíková filtrace, analýza a restaurace signálů*. Vyd. 2. Brno: VUTIUM, 2002, 427 s. ISBN 80-214-1558-4.
- [12] JAN, J. *Medical Image Processing, Reconstruction and Restoration: Concepts and Methods*. Boca Raton: Taylor, 2006, 730 s. ISBN 978-3-642-24693-7.
- [13] KALENDER, W. A., KLOTZ, E. a SUESS, C. *Vertebral bone mineral analysis: An integrated approach with CT*. Radiology. 1987, vol. 164, p. 419-423.

- [14] KANG, Y., ENGELKE, K., KALENDER, W. A., KARANGELIS, G. a ZIMERAS, S. *A New Accurate and Precise 3-D Segmentation Method for Skeletal Structures in Volumetric CT Data*. IEEE Transactions on Medical Imaging. 2003, vol. 22, issue 5, s. 370-373.
- [15] KITCHEN, M. J., PAGANIN, D. M., UESUGI, K. ALLISON, B. J., LEWIS, R. A., HOOPER, S. B. a PAVLOV, K. M. *X-ray phase, absorption and scatter retrieval using two or more phase contrast images*. Optics Express. 2010, vol. 18, issue 19.
- [16] KOUNTCHEV, R., NAKAMATSU K. *Advances in Reasoning-Based Image Processing Intelligent Systems: Conventional and Intelligent Paradigms*. 1st ed. New York: Springer, 2011, p. cm. ISBN 978-364-2246-920.
- [17] NABOUT, A. A. *Object Shape Recognition Using Wavelet Descriptors*. Journal of Engineering. 2013, vol. 2013, s. 1-15.
- [18] NATIONAL ELECTRICAL MANUFACTURERS ASSOCIATION. *Digital Imaging and Communications in Medicine (DICOM) Part 1: Introduction and Overview*. National Electrical Manufacturers Association 1300 N. 17th Street, Rosslyn, Virginia 22209 USA, 2011.
- [19] OTSU, N. *A Threshold Selection Method from Gray-Level Histograms*. IEEE Transactions on Systems, Man, and Cybernetics. 1979, vol. 9, issue 1, s. 62-66.
- [20] PARK, F. *Přednáška: Shape Descriptor/Feature Extraction Techniques* [online]. UCI iCAMP, 2011. [cit. 23. 12. 2013]. Dostupné z URL: <<http://www.math.uci.edu/icamp/summer/research.pdf>>.
- [21] PEURA, M., IIVARINEN, J. *Efficiency of Simple Shape Descriptors*. Proceedings of the Third International Workshop on Visual Form. 1997, pp. 443-451.
- [22] RAMER, U., CHAN, W. *An Iterative Procedure for the Polygonal Approximation of Plane Curves*. Computer Graphics and Image Processing. 1972, vol. 1, issue 3, s. 244-256.
- [23] RÓNTGEN, W. C. *On a New Kind of Rays*. Resonance. 2005, vol. 10, issue 6, s. 89-95.
- [24] TVRDÍK, J. *Evoluční algoritmy*. 1. vyd. Ostrava, Ostravská univerzita, 2004, 73 s.
- [25] WALEK, P., JAN, J., OUŘEDNÍČEK, P., SKOTÁKOVÁ, J. a JÍRA, I. *Pre-processing for Quantitative Statistical Noise Analysis of MDCT Brain Images*

- Reconstructed Using Hybrid Iterative (iDose) Algorithm.* Journal of WSCG, 2012, roč. 20, č. 1, s. 73-80. ISSN: 1213- 6972.
- [26] WANG, L. I., GREENSPAN, M. a ELLIS, R. *Validation of Bone Segmentation and Improved 3-D Registration Using Contour Coherency in CT Data.* IEEE Transactions on Medical Imaging. 2006, vol. 25, issue 3, s. 324-334.
- [27] WHITCHER, B., SCHMID, V. J. a THORNTON, A. *Working with the DICOM and NIfTI Data Standards in R.* Journal of Statistical Software. 2011, vol. 44, issue 6, s. 1-28.
- [28] YOUNG, I. T., WALKER, J. E. a BOWIE, J. E. *An Analysis Technique for Biological Shape. I.* Information and Control. 1974, vol. 25, issue 4, s. 357-370.
- [29] ZAHN, CH. T., ROSKIES, R. Z. *Fourier Descriptors for Plane Closed Curves.* IEEE Transactions on Computers. 1972, C-21, issue 3, s. 269-281.
- [30] ZHANG, D., LU, G., SONKA, M., HLAVAC, V. a BOYLE, R. *Review of shape representation and description techniques.* Pattern Recognition. 2004, vol. 37, issue 1, s. 192-254.
- [31] ZHANG, J., YAN, C. H., CHUI, C. K. a ONG, S. H. *Fast segmentation of bone in CT images using 3D adaptive thresholding.* Computers in Biology and Medicine. 2010, vol. 40, issue 2, s. 231-236.

## SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

ACR American College of Radiology

CT výpočetní tomografie (*angl.* Computed Tomography)

CTPA CT plicní angiografie (*angl.* CT Pulmonary Angiogram)

CWT spojitá vlnková transformace (*angl.* Continuous Wavelet Transform)

DFT diskrétní Fourierova transformace

DICOM Digital Imaging and Communications in Medicine

EKG elektrokardiogram

FDs Fourierovy deskriptory (*angl.* Fourier Descriptors)

FFT rychlá Fourierova transformace (*angl.* Fast Fourier Transform)

FT Fourierova transformace

HU Hounsfieldova jednotka (*angl.* Hounsfield Unit)

ICHS ischemická choroba srdeční

LSQ metoda nejmenších čtverců (*angl.* Least Squares)

MRI magnetická rezonance (*angl.* Magnetic Resonance Imaging)

MSE střední kvadratická odchylka (*angl.* Mean Squared Error)

NEMA National Electrical Manufacturers Association

PP primární parametr

PPP primární parametrické pole

RGB barevný model složený ze tří komponent: Red, Green, Blue

RTG rentgenové

WDs vlnkové deskriptory (*angl.* Wavelet Descriptors)


WT vlnková transformace (*angl.* Wavelet Transform)

## SEZNAM PŘÍLOH


A Originální obrazová CT data	65
B Výsledky detekce potenciálně chybně segmentovaných kostí	66




## A ORIGINÁLNÍ OBRAZOVÁ CT DATA



(a)




(b)




(c)

Obr. A.1: Originální snímky pro vizuální kontrolu správnosti výsledku.

## B VÝSLEDKY DETEKCE POTENCIÁLNĚ CHYBNĚ SEGMENTOVANÝCH KOSTÍ





Obr. B.1: Ukázka výsledků detekce potenciálně chybně segmentovaných kostí: (vlevo) originální data; (vpravo) binární obraz reprezentující segmentované kosti se zakreslenými pozicemi přerušení.