

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
ÚSTAV TELEKOMUNIKACÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF TELECOMMUNICATIONS

TVORBA 3D MODELU ČELISTNÍHO KLOUBU

DIZERTAČNÍ PRÁCE
DOCTORAL THESIS

AUTOR PRÁCE
AUTHOR

Ing. ONDŘEJ ŠMIRG

BRNO 2014



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**
ÚSTAV TELEKOMUNIKACÍ

**FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF TELECOMMUNICATIONS**

TVORBA 3D MODELU ČELISTNÍHO KLOUBU

CREATING 3D MODEL OF TEMPOROMANDIBULAR JOINT

DOKTORSKÁ PRÁCE
DOCTORAL THESIS

AUTOR PRÁCE
AUTHOR

ING. ONDŘEJ ŠMIRG

VEDOUcí PRÁCE
SUPERVISOR

PROF. ING. ZDENĚK SMÉKAL, CSC.

BRNO 2014

Abstrakt

Dizertační práce pojednává o 3D rekonstrukci temporomandibulárního kloubu z 2D řezů tkání získané z magnetické rezonance. Současná praxe používá 2D MRI řezů pro určení diagnózy. 3D model má mnoho výhod pro určení diagnózy, které vycházejí ze znalosti prostorové informace. Současná medicína používá 3D modely tkání, ale u tkáně čelistního kloubu existuje problém se segmentací kloubního disku. Tato malá tkáň, která má malý kontrast a velice podobné statistické vlastnosti, jako její okolí, lze jen složitě segmentovat. Pro segmentaci kloubního disku byly vyvinuty nové metody založené na znalosti anatomie oblasti kloubního disku a dále na statistice využívající genetického algoritmu. Soubor 2D řezu má různé rozlišení v osách x,y a ose z. Pro sjednocení rozlišení byl vyvinut algoritmus nadvzorkování, který se snaží zachovat tvarové vlastnosti tkáně. V poslední fázi tvorby 3D modelů bylo využito již standardně používaných metod, avšak tyto metody pro decimaci a vyhlazení mají různé možnosti nastavení (počet polygonů modelu, počet iterací algoritmu). Protože výsledkem práce je získání co nejvěrnějšího modelu reálné tkáně, bylo nutné vytvořit objektivní metody, pomocí kterých by bylo možné nastavit algoritmy tak, aby bylo dosaženo co nejlepšího kompromisu mezi mírou zkreslení a dosažením věrohodnosti modelu.

Klíčová slova

Zpracování obrazu, segmentace obrazů, aktivní kontury, genetické algoritmy, polygonální modely, vyhlazování, decimace, vzorkování, interpolace

Abstract

The dissertation thesis deals with 3D reconstruction of the temporomandibular joint from 2D slices of tissue obtained by magnetic resonance. The current practice uses 2D MRI slices in diagnosing. 3D models have many advantages for the diagnosis, which are based on the knowledge of spatial information. Contemporary medicine uses 3D models of tissues, but with the temporomandibular joint tissues there is a problem with segmenting the articular disc. This small tissue, which has a low contrast and very similar statistical characteristics to its neighborhood, is very complicated to segment. For the segmentation of the articular disk new methods were developed based on the knowledge of the anatomy of the joint area of the disk and on the genetic-algorithm-based statistics. A set of 2D slices has different resolutions in the x-, y- and z-axes. An up-sampling algorithm, which seeks to preserve the shape properties of the tissue was developed to unify the resolutions in the axes. In the last phase of creating 3D models standard methods were used, but these methods for smoothing and decimating have different settings (number of polygons in the model, the number of iterations of the algorithm). As the aim of this thesis is to obtain the most precise model possible of the real tissue, it was necessary to establish an objective method by which it would be possible to set the algorithms so as to achieve the best compromise between the distortion and the model credibility achieve.

Keywords

Image processing, image segmentation, active contours, genetic algorithm, polygon mesh, smoothing, decimation, sampling, interpolation

PROHLÁŠENÍ

Prohlašuji, že svou doktorskou práci na téma „Tvorba 3D modelu čelistního kloubu“ jsem vypracoval samostatně pod vedením vedoucího doktorské 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 doktorské práce dále prohlašuji, že v souvislosti s vytvořením této doktorské 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)



Vedoucí práce

Supervisor

prof. Ing. Zdeněk Smékal, CSc.



Školitel specialista

Co-supervisor

Marcos Faundez-Zanuy
Escola Universitària Politècnica de Mataró (UPC), Spain

Poděkování

Děkuji svému školiteli prof. Ing. Zdeňku Smékalovi, CSc. za odborné vedení a velice cenné připomínky při zpracování disertační práce. Dále děkuji všem ostatním, kteří ke vzniku práce přispěli, zejména MUDr. Andree Šprlákové-Pukové, MUDr. et MUDr. Ondřeji Liberdovi Ph.D. a prof. Marcos Faundez-Zanuy.

V Brně

.....
Ing. Ondřej Šmirg

Výzkum popsáný v této dizertační práci byl realizován v laboratořích podpořených z projektu SIX; registrační číslo CZ.1.05/2.1.00/03.0072, operační program Výzkum a vývoj pro inovace.

Obsah

1	ÚVOD	10
2	TEMPOROMANDIBULÁRNÍ KLOUB	12
2.1	ANATOMIE TEMPOROMANDIBULÁRNÍHO KLOUBU	12
3	DOSAVADNÍ VÝVOJ	19
3.1	DIAGNOSTICKÉ METODY PRO ZÍSKÁNÍ VSTUPNÍCH DAT	19
3.2	FILTRACE OBRAZU	29
3.3	SEGMENTAČNÍ METODY	34
3.4	TVORBA 3D MODELU	42
4	CÍLE DIZERTACE	44
5	TEORETICKÁ ANALÝZA NOVĚ NAVRŽENÝCH METOD	44
5.1	SEGMENTACE KLOUBNÍ HLAVICE Z MRI SNÍMKŮ	44
5.2	SEGMENTACE KLOUBNÍHO DISKU	55
5.3	TVORBA 3D MODELU	71
6	VÝSLEDKY DIZERTAČNÍ PRÁCE	79
6.1	VSTUPNÍ DATA	79
6.2	FILTRACE DAT	80
6.3	RUČNÍ SEGMENTACE	83
6.4	OBJEKTIVNÍ VYHODNOCENÍ SEGMENTACE	85
6.5	VÝSLEDKY SOUČASNÝCH METOD A VYHODNOCENÍ SEGMENTACE KLOUBNÍ HLAVICE ...	86
6.6	VYHODNOCENÍ SEGMENTACE KLOUBNÍHO DISKU	93
6.7	NADVZORKOVÁNÍ DAT A TVORBA 3D MODELU	97
6.8	3D TISK	106
7	ZÁVĚR	107
	SEZNAM POUŽITÉ LITERATURY	109
	SEZNAM PŘÍSPĚVKŮ AUTORA	115
	SEZNAM OBRÁZKŮ	117
	SEZNAM TABULEK	120
	CURRICULUM VITAE	121

Seznam použitých zkratek

2D	dvojměrný
3D	trojměrný
AAM	metoda segmentace modelem (<i>active appearance model</i>)
ASM	metoda segmentace tvarem modelu (<i>active shape models</i>)
CNR	poměr kontrast/šum(<i>contrast-to-noise ratio</i>)
CT	počítačová tomografie
DICOM	protokol pro přenos medicínských dat
DPI	počet pixelů na délku jednoho palce (<i>dots per inch</i>)
DTWT	waveletová transformace s diskretním časem (<i>discrete time wavelet transform</i>)
DWT	diskretní waveletová transformace (<i>discrete wavelet transform</i>)
FF	pozice pacienta nohama napřed (<i>feet first</i>)
FOV	viditelná oblast mr (<i>field of view</i>)
GAČR	grantová agentura české republiky
HF	pozice pacienta hlavou napřed (<i>head first</i>)
HFS	pozice pacienta hlavou napřed na zádech (<i>head first-supine</i>)
HOG	histogram orientovaných gradientů (<i>histogram of oriented gradient</i>)
ITK	knihovna pro zobrazování dat (<i>insight tool kit</i>)
LPS	pozice pacienta k souřadnému systému (<i>left, posterior, superior</i>)
LSE	chyba metody nejmenších čtverců (<i>least square error</i>)
LSM	Level set metoda (<i>level-set method</i>)
MPR	multiplanární rekonstrukce
MR	magnetická rezonance
MRF	markovská náhodná pole (<i>Markov random field</i>)
MRI	zobrazování metodami magnetické rezonance (<i>magnetic resonance imaging</i>)
NMR	nukleární magnetická rezonance (<i>nuclear magnetic resonance</i>)
PCA	metoda analýzy hlavních komponent (<i>principle component analysis</i>)
PD	protonová denzita (<i>proton density</i>)
RMS	efektivní hodnota (<i>root mean square</i>)
RTG	rentgen
SNR	odstup signálu od šumu(<i>signal-to-noise ratio</i>)
TMK	čelistní kloub
mSv	milisievert
mGy	miligray

1 Úvod

Od doby kdy Albert Einstein dostal Nobelovu cenu za vysvětlení fotoefektu, uplynulo více jak 80 let, ale teprve s vývojem výpočetní techniky se stalo odvětví zpracování takto získaných obrazových dat velice atraktivní disciplínou. I když počátek této disciplíny souvisí s fotovoltickým jevem, v dnešní době už je toto odvětví rozšířeno i na další způsoby získávání obrazové informace, jakým je například rentgenové záření, ultrazvukové vlny atd. Aplikace metod pro zpracování obrazu se využívá v mnoha oblastech lidské působnosti, jakými jsou výrobní procesy, bezpečnostní aplikace a v neposlední řadě i zpracování medicínských obrazů. Právě obor zpracování medicínských obrazů se nyní dostává do popředí, protože byly vyvinuty neinvazivní metody (metody nenarušující pokožku ani tělesné dutiny mechanickým zásahem) pro získávání obrazů vnitřních orgánů těla. Mezi nejčastěji používané neinvazivní zobrazovací metody v medicíně patří sonograf, RTG a CT tomografie [1]. Každá z těchto metod má své opodstatnění pro různé typy tkání a také se zde musí brát ohled na ekonomickou stránku věci, kdy tkáně, které lze jednoznačně diagnostikovat pomocí sonografu, nemusí být diagnostikovány na základě magnetické rezonance.

V technické praxi se pro zpracování dat získaných z NMR používá zkratka MRI (Magnetic Resonance Imaging [2][3]). Pro rekonstrukci 3D objektu z řezů MRI je nutné provést s řezy celou řadu na sebe navazujících kroků. Jako první operace se provádí předzpracování obrazu (geometrické a jasové transformace, filtrace šumu, detekce hran, rozostření, zaostření), které má za úkol zvýšit odstup užitečného signálu od šumu a zvýraznit tak tu část obrazu, která se bude následně zpracovávat. Následující operací je segmentace obrazu. Jedná se o proces, kdy se obraz rozdělí na jednotlivé oblasti, které musí splňovat určité kritérium [4]. Segmentace obrazu a správný popis jednotlivých objektů patří mezi nejsložitější oblasti zpracování a mají velký vliv na přesnost výsledků [4][5]. Vlastní tvorba 3D modelu potom závisí na kvalitě segmentované tkáně a i při tvorbě 3D modelu je velice důležité přizpůsobovat operace s modelem tak, abychom co nejvíce zachovali jeho tvarové vlastnosti, které jsou nejvíce vypovídajícím aspektem pro vlastní stanovení diagnózy [6]. 3D modely umožňují jak specialistům v oboru radiologie pomoci s diagnózou, tak specialistům z oboru chirurgie pomoci s předoperační přípravou. Vlastní tvorba 3D modelu se tak musí zaměřovat nejen na správné grafické vyjádření modelu, ale i na vzájemnou polohu modelovaných tkání.

Tvorba 3D modelů tkání je už běžnou praxí u mnoha částí lidského těla a nejčastěji se provádí z dat počítačové tomografie, která s vysokou mírou kvality dokáže rozlišit hlavně tvrdé tkáně [7]. Toho se využívá např. při stomatologii, traumatologii, ale i u mnoha dalších lékařských oborů. Pro měkké tkáně, které není možné dostatečně kvalitně zobrazit v CT, se využívá nukleární magnetická rezonance. Magnetická rezonance je oproti počítačové tomografii univerzální metodou a různými typy sekvencí je možné rozlišit různé tkáně [2]. Tato dizertační práce se zabývá oblastí tvorby 3D modelu u temporomandibulárního kloubu (TMK). V dosavadní praxi se pro diagnostiku tohoto kloubu používají všechny výše zmíněné neinvazivní techniky. Pro určení vlastností pohybu TMK se používá sonografie, pro určení disfunkcí pevných částí a zlomenin v oblasti TMK se používá RTG nebo CT. Avšak pro případy disfunkcí měkkých tkání čelistního kloubu se užívá obraz z NMR v 2D řezech. Právě vzájemná poloha měkkých a tvrdých tkání je nejdůležitější oblastí pro správnou diagnózu disfunkcí TMK.

Statisticky bylo zjištěno, že 33% obyvatelstva trpí onemocněním čelistního kloubu a že čelistní kloub je druhou nejčastější příčinnou bolestí hlavy [9]. Temporomandibulární kloub je jedním z nejsložitějších kloubů lidského těla. Je kloubem složeným, mezi kloubním výběžkem dolní čelisti a kloubní jamkou (glenoidální fossa) spánkové kosti se nachází kloubní disk. Čelistní kloub je kloubem rotačně- translačním. Při otevírání úst dochází mezi diskem a hlavicí k rotaci a komplex kloubní hlavice a disku provádí v kloubní jamce pohyb translační. Vazy nezasahují aktivně do pohybu v kloubu, ale působí jako pasivní omezující zařízení k omezení pohybů uvnitř kloubu. Nejčastější příčina problémů s čelistním kloubem je způsobena kloubním diskem (diskus artikularis) [12][13]. Kloubní disk je sedlovitě prohnutá vazivová chrupavka mezi kloubní hlavicí a kloubní jamkou, která se pohybuje společně s kloubní hlavicí [13]. Jedná se o problém celosvětového měřítka [9], [10], [11], protože právě špatná diagnóza může prohlubovat problémy způsobené onemocněním čelistního kloubu, které mohou vést až k problémům s příjmem potravy, nebo s verbální komunikací. Nejčastější příčiny onemocnění čelistního kloubu souvisí s kloubním diskem. V současné době se diagnóza související s kloubním diskem provádí pomocí 2D snímků magnetické rezonance. Bohužel se u 2D snímků ztrácí informace o prostorové poloze kloubního disku vůči kloubní hlavicí. Aby bylo možné určit vzájemnou prostorovou polohu kloubního disku a kloubní hlavice, musí se vytvořit jejich trojrozměrný model. V dnešní době existují lékařské postupy, ze kterých se vytvářejí 3D modely čelistního kloubu a to pro potřeby traumatologie [7]. Tyto trojrozměrné modely se vytváří na základě snímků z CT, kde je vysoké rozlišení pevných tkání, bohužel kloubní disk je tkání měkkou, která není na snímcích CT dostatečně viditelná a nelze ji tedy rekonstruovat do 3D modelu. Jedinou možností jak vytvořit 3D model čelistního kloubu s kloubním diskem je zrekonstruovat model z informací obsažených ve 2D MRI snímcích. Tyto snímky kromě vlastních 2D dat obsahují i informaci o poloze těchto dat v prostoru a je tedy možné z nich rekonstruovat 3D model čelistního kloubu.

Právě rekonstrukce čelistního kloubu včetně měkkých tkání má velký význam pro lékařskou praxi a je hlavní náplní práce, která se snaží o co nejlepší výsledek na základě kombinace informací obsažených v datech a informací získaných od odborníků z oboru radiologie. V současné době se čím dál více využívá 3D rekonstrukce tkání v různých oborech lékařství. Je tedy důležité rozšiřovat oblasti, ve kterých je možné tyto metody použít a umožnit tak plně využít potenciálu obtížně získaných dat, u kterých je využíván jen zlomek jejich informace. Přestože vývoj metod pro segmentaci a rekonstrukci 3D modelu pokročily velice dopředu, nelze je efektivně využít pro segmentaci kloubního disku. Kloubní disk má bohužel statisticky velice podobné vlastnosti jako jeho okolní tkáň, a tím znemožňuje použití současných metod k jeho oddělení od okolní tkáně. Výsledky práce ukazují, že za pomoci anatomických vlastností oblasti s kloubním diskem lze efektivně oddělit tkáň kloubního disku od jeho okolí a zrekonstruovat jeho 3D model. Správnost tvaru kloubního disku zrekonstruovaného 3D modelu potvrdili i čelistní chirurgové, kteří mají možnost vidět skutečnou tkáň kloubního disku.

Hlavní přínos této práce spočívá v nových technikách segmentace kloubního disku a kloubní hlavice, metody pro nadzorkování binární masky a využití objektivního vyhodnocování hloubky decimace (zmenšování počtu polygonů v polygonální síti) a počtu iterací vyhlazovacího algoritmu. Navržené metody segmentace využívající rozšíření metody rozvodí u kloubní hlavice a kombinace znalosti anatomie čelistního kloubu se statistikou využívající genetického algoritmu u kloubního disku dosáhly $87,7\% \pm 3,8\%$ účinnosti u kloubní hlavice a $71,5\% \pm 3,2\%$ u kloubního disku. Dosáhly tak lepších výsledků, jaké byly dosaženy s experimentálně nejlepším možným nastavením level-set metody, kde její účinnost činila $78,5\% \pm 8,4\%$ u kloubní hlavice a $61,3\% \pm 4,8\%$ u kloubního disku. Výsledky korelují i s ruční segmentací, která u kontrastnější kloubní hlavice dosahuje účinnosti 93% a u

kloubního disku, který je mnohem složitější pro segmentaci, dosahuje zdatně menší 82,6% účinnosti. Je tedy vidět, že nové metody dosahují dobrých výsledků i v porovnání s ruční segmentací, kterou můžeme označit jako zlatý standart. V oblasti nadvzorkování, decimace a vyhlazování jde hlavně o nalezení kompromisu mezi tvarovým zkreslením a přiblížením se reálné podobě tkáně. Zde bylo provedeno subjektivní zhodnocení výsledného modelu čelistním chirurgem, který zhodnotil model jako velice podobný skutečné tkáni a využil model vytištěný pomocí 3D tiskárny pro studijní potřeby.


Zbytek této práce je rozdělen do následujících oblastí: V první kapitole se práce zaměřuje na anatomické vlastnosti a uspořádání tkání čelistního kloubu. Tato kapitola je důležitá pro následné pochopení principu, podle kterého byla zvolena oblast pro vyhledávání kloubního disku. Druhou kapitolou je dosavadní vývoj, který mapuje jednak principy získávání vstupních dat a jejich individuální vlastnosti a dále pak moderní metody segmentace biomedicínských dat a principy jejich 3D rekonstrukce. Jedná se o průřez současného stavu vědy a techniky v oblasti 3D rekonstrukce tkání v celém řetězci zpracování. Další kapitola popisuje princip nových metod použitých pro 3D rekonstrukci čelistního kloubu. V první fázi je popsán celý řetězec zpracování a postupně jsou rozebrány jednotlivé části. Poslední částí práce je zhodnocení a porovnání nově navržených metod se současným stavem vědy a techniky. Jsou zde popsány techniky pomocí, kterých je možné porovnávat účinnost algoritmů a dále výsledky jednotlivých algoritmů porovnané s ruční segmentací, která je brána jako zlatý standart. Výzkum algoritmů byl prováděn v rámci projektů GAČR 102/12/1104, KONTAKT ME10123 za přispění centra SIX v rámci podpory MSM ED2.1.00/03.0072 a spolupráce se zahraničními institucemi Universitat Politècnica de Catalunya a Hospital de Mataró a University of Southern California.

2 Temporomandibulární kloub

Onemocnění TMK trápily už starověké Egyptany [8] a jako první si dal symptomy bolesti hlavy do souvislosti se špatnou funkcí TMK Hippocrates. Základními symptomy mohou být bolest v oblasti TMK, bolest v oblasti spánkového svalu (musculus temporalis), omezené otevírání úst, nebo patologické zvuky z oblasti TMK. Přestože se jedná o nepříliš známé onemocnění, ve skutečnosti je velice časté a to hlavně ve věkové skupině mezi 20 a 40 lety. Dokonce se jedná o druhou nejčastější příčinu bolesti hlavy, po bolesti způsobenou onemocněním zubů. Statisticky 33% populace vykazuje minimálně jeden z příznaků onemocnění TMK [9] a 3,6 – 7% populace má potíže takového charakteru, že vyhledá ošetření lékaře [10]. Neléčené onemocnění TMK může zahrnovat i další symptomy jako otalgii (bolest ucha, která není způsobena onemocněním ucha), závratě, tinnitus (jedná se o šelest v uších, která může v různých intervalech zesilovat), bolest šíje, nebo bolest v oblasti chrupu. Dále může onemocnění TMK přispět i ke vzniku migrény, tenzních bolestí hlavy, a mnoha dalším potížím, které přímo nesouvisejí s oblastí TMK.

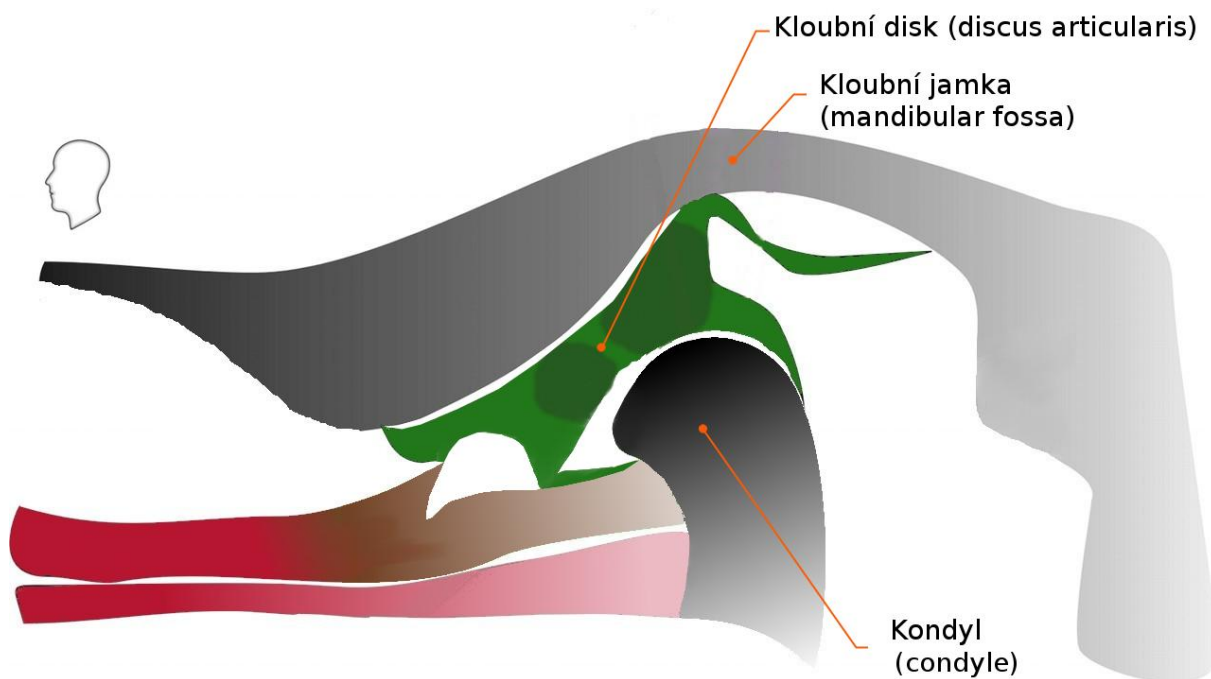
2.1 Anatomie temporomandibulárního kloubu

Hlavní jádro TMK je složeno ze tří částí, kloubní hlavice (kondyl), kloubní jamky (mandibular fossa) a kloubního disku (diskus). U kloubní hlavice a kloubní jamky se jedná o tvrdé tkáně, zatímco kloubní disk je měkká tkáň. Tvar kloubní hlavice je individuální pro různé pacienty. V 60% případů má kloubní hlavice okrouhlý nebo konvexní tvar, a u přibližně 20-30% případů se jedná o vzácné tvary. [13] Tvary kloubní hlavice můžete vidět na obr. 2.1.




Obr. 2.1: Kloubní hlavice (vlevo okrouhlý tvar, vpravo plochý tvar) - převzato ze zdroje [13]

Úhel longitudinálních os kloubní hlavice s frontální rovinou je 0° - 30° . Kloubní hlavice měří přibližně 13-25mm mediolaterálně a 5,5-16mm anteroposteriorně. Kloubní jamka se nachází na spodině lebeční a má konkávní tvar. Mezi kloubní hlavici a kloubní jamkou se nachází kloubní disk. Kloubní disk je flexibilní struktura typu chrupavčité ploténky se specializovaným tvarem, který má přední (2mm) a zadní (3mm) zesílení a intermediální zónu (1mm). Kloubní disk s jeho úpony rozdělují kloubní prostor na horní kloubní štěrbinu a dolní kloubní štěrbinu. Horní kloubní štěrbinu přesahuje dolní kloubní štěrbinu v sagitálním i frontálním směru. Při pohybu čelisti se kloubní disk pohybuje vždy nad kloubní hlavici, proto je důležitá právě vzájemná poloha disku a kloubní hlavice. Uvnitř TMK se nachází kloubní tekutina, která zajišťuje výživu chrupavky a zároveň funguje jako lubrikant. Na obr. 2.2 můžete vidět anatomii TMK kloubu. Zeleně je vyznačen kloubní disk. Bílé oblasti nad a pod kloubním diskem jsou horní a dolní kloubní štěrbinu. Červená barva značí vazy. Tmavá barva značí pevné části kloubu, tedy kloubní hlavici a kloubní jamku. Zeslabené části kloubního disku na jeho koncích jsou úpony.[11] Ty se dělí na zadní úpon (posteriori attachment, bilaminární zona, retrodiskální polštář) a úpon do temporální kosti a krčku kloubní hlavice. Přední zesílené kloubního disku se upíná do kloubního pouzdra.[13] Protože se tato práce zaměřuje na vzájemnou polohu kloubního disku a kloubní hlavice jsou tyto úpony disku nepodstatné, a proto nejsou v obrázku vyznačeny.




Obr. 2.2: Anatomie temporomandibulárního kloubu při zavřených ústech [12]

Kromě popsaných vlastností jednotlivých částí jsou velmi důležité i vlastnosti jejich vzájemné polohy a to hlavně kloubního disku a kloubní hlavice [11] Obr. 2.3 ukazuje hranici polohy kloubního disku a kloubní hlavice, za níž už je stav kloubu považován za patologický. Obrázek vykresluje princip vyhodnocování patologie popsaný tak, že pokud je zadní část (posterior band) disku posunuta o více než 10° od vertikální pozice kloubní hlavice, jedná se o patologický stav. Ovšem podle studie popsané ve zdroji [12] lze považovat patologický stav až při posunu arteriální oblasti disku větším jak 30° .

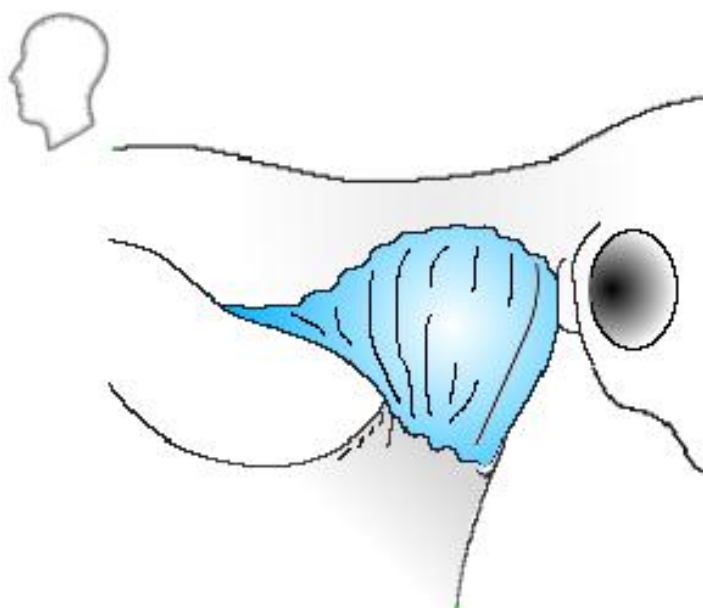


Obr. 2.3: Princip vyhodnocení patologické pozice disku [12]




Obr. 2.4: Princip vyhodnocení patologické pozice disku podle studie ve zdroji [12]

Z pohledu segmentace disku nám obr. 2.3 a obr. 2.4 popisují nejčastější polohu disku v běžné populaci. Poloha a hlavně způsob určování patologie disku jsou velmi důležité faktory pro vlastní segmentaci, protože nám vymezují prostor, ve kterém by se měl nacházet zdravý kloubní disk v závislosti na kloubní hlavici. Protože TMK je uzavřen do pouzdra, je oblast kde se může kloubní disk nacházet a to i při patologii prostorem pouzdra omezena. Kloubní pouzdro je navíc zesílené laterálně temporomandibulárním ligamentem (vazem). Jak je vidět na obr. 2.5.



Obr. 2.5: Pouzdro TMK tvořené temporomandibulárním ligamentem [13]

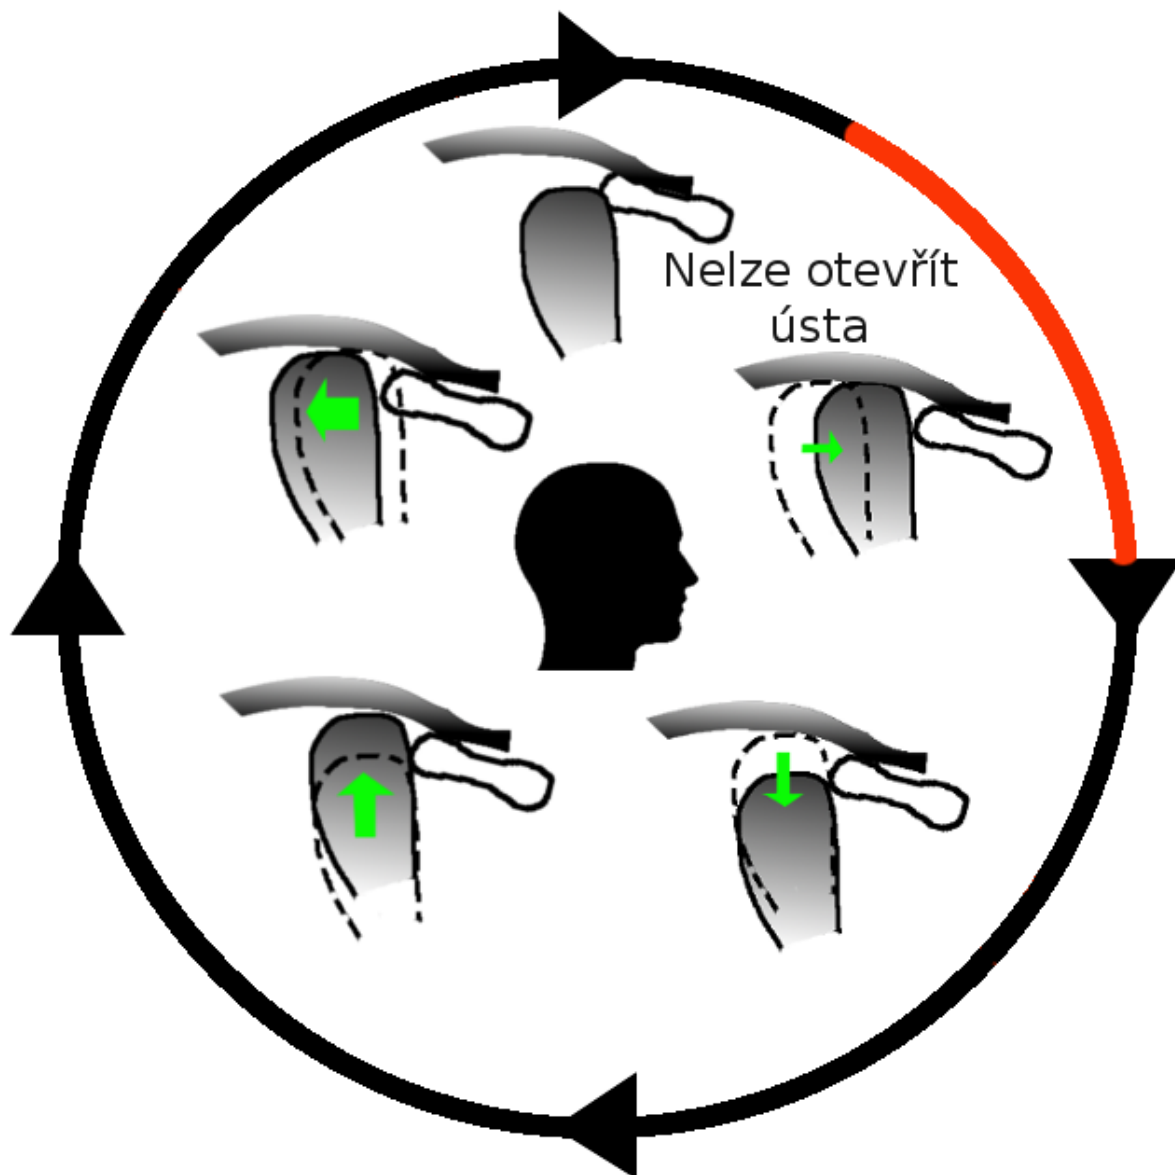
Přestože je pohyb disku vymezen kloubním pouzdrem může dojít k jeho dislokaci vůči kloubní hlavici. Pokud se jedná o stav, kdy se disk alespoň částečně vrací na svoji pozici, mluvíme o **dislokaci disku s repozicí**. Tento stav je nejčastější diagnosou u pacientů s klikáním či lupáním v oblasti TMK.[14][15] Při tomto stavu dochází k ventrální dislokaci disku (disk je posunut směrem před kloubní hlavici směrem k obličejí). Při začátku otevírání dochází nejprve k rotaci kloubní hlavice a následně k jeho pohybu vpřed, kdy dojde k přeskočení kondylu přes přední zesílenou zónu do zóny intermediální (u kloubní hlavice). V případě zavírání nejprve disk zůstává v oblasti intermediální a v poslední fázi se vrací do oblasti pod kloubní hlavici, což způsobí opět klik, či lupnutí. [13] Rozfázovaný průběh je vidět na obr. 2.6.



Obr. 2.6: Rozfázovaný pohyb čelisti u dislokace disku s repozicí [13]

Druhou možností onemocnění kloubního disku je **akutní dislokace disku bez repozice**. [13] Tento stav způsobuje trvalé výrazné omezení otvírání čelistí a to pod hodnotu 35mm (mezi zuby). V tomto případě dochází opět k dislokaci disku při pohybu kloubní hlavice ve ventralním směru, avšak tentokrát disk není schopen přejít do intermediální zóny a působí v oblasti jako překážka v pohybu. Pokud se pacient pokusí otevřít ústa více, druhý nepostižený kloub se pohybuje v plném fyziologickém rozsahu a dochází k deviaci čelisti

směrem k poškozené straně. Akutní dislokace ve většině případů po klidovém režimu ustoupí a pacientovi umožňuje opětovný plný rozsah otevření. V určitém počtu případů však postupně může přejít do **chronické dislokace bez repozice** spojené s trvalou deviací v oblasti TMK. Ukázka rozfázovaného pohybu čelisti u dislokace bez repozice je vidět na obr. 2.7.



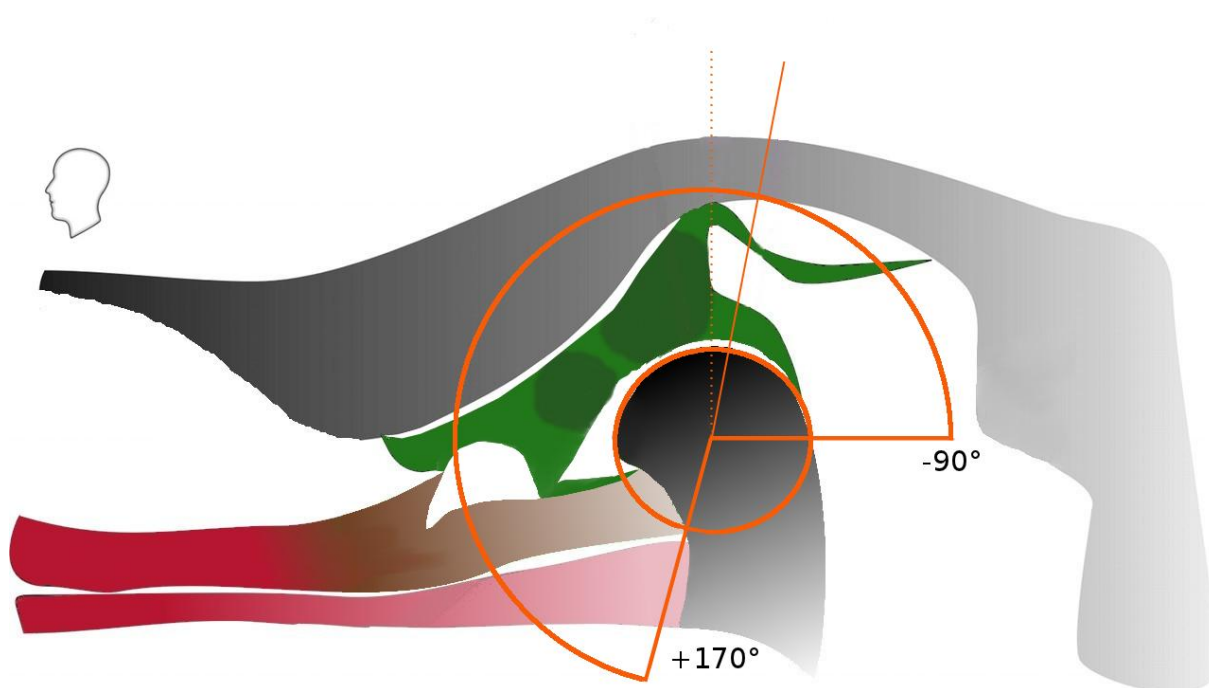
Obr. 2.7: Rozfázovaný pohyb čelisti u dislokace disku bez repozice [13]

Dislokace disku TMK je posuzována pomocí široce přijímané Wilkesovy klasifikace, která určuje závažnost a chronicitu dislokace disku. Wilkesova klasifikace vychází z tab. 2.1, kde jsou popsána jednotlivá stádia od dislokace s repozicí až po chronickou dislokaci bez repozice.

Tab. 2.1: Wilkesova klasifikace diskopatií [13][16]

Stádium	Popis
I	Častá dislokace disku s repozicí
II	Pozdní dislokace disku s repozicí
III	Dislokace disku bez repozice: akutní/subakutní
IV	Dislokace disku bez repozice: chronická
V	Dislokace disku bez repozice: chronická s osteoartrosou

Jak je z tab. 2.1 patrné, jsou diskopatie popsány na obr. 2.6 a obr. 2.7 hraničními případy. Jak je navíc popsáno ve zdroji [14], případy kdy se jedná o posteriorně dislokovaný disk, jsou velice vzácné a je možné je pro účely segmentačních algoritmů zanedbat. To nám umožňuje stanovit pozici disku v závislosti na kloubní hlavici, jak pro zdravého člověka, tak i pro všechny případy diskopatií popsány ve Wilkensově klasifikaci [13].




Obr. 2.8: Vymezená oblast možného výskytu disku pro zdravý i dislokovaný disk

Hraniční úhly z obr. 2.8 vymezují prostor, kde se může nacházet kloubní disk. Úhel od -10° po -90° je méně pravděpodobný prostor, kde se může disk nacházet, ale i tak je do této oblasti zahrnut. Hlavní oblast je v prostoru mezi -10° a přibližně $+170^\circ$. Tento prostor byl zvolen na základě Wilkensovy klasifikace a určení diskopatie na základě poznatků ze zdroje [12]. Úhel 170° je přibližný a přesněji se určuje podle hranice tkáně kloubní hlavice, která je vymežující prvkem pro pohyb kloubního disku.

3 Dosavadní vývoj

Jak bylo uvedeno výše, disertační práce je zaměřena do oblasti metod zpracování biomedicínických dat získaných z neinvazivních diagnostických zařízení, která se v dnešní době v medicíně používají. Tvorba trojrozměrných modelů tkání vychází ze získaných trojrozměrných dat reprezentovaných sekvencemi dvourozměrných dat nesoucí informaci o prostorovém uspořádání. Moderní neinvazivní diagnostické metody poskytují nejen standardní 2D rovinné snímky, ale dokáží poskytovat i posloupnost na sebe navazujících rovinných snímků, které nám poskytují informaci o situaci, struktuře a další informace o snímané tkáni. Aby bylo dosaženo standardního uložení těchto dat i s danými informacemi, byl pro tyto účely vytvořen protokol s názvem DICOM, který dokáže zachovávat veškeré informace o těchto datech, včetně jejich rovinných reprezentací. V dnešní době je nejpoužívanější verze tohoto protokolu DICOM 3.0 [17]. Protože tato data obsahují plnou reprezentaci všech lidských tkání daného řezu, je nutné nejprve separovat pouze tu tkáň, o kterou se zajímáme. Z toho důvodu jsou v první fázi tyto data předzpracovány segmentační metodou a následně převedeny do polygonálního modelu, kterým je tkáň reprezentována, jak je popsáno v [18]. Celý proces lze blokově popsat pomocí následujícího obrázku.



Obr. 3.1: Blokové schéma tvorby trojrozměrného objektu tkání

3.1 Diagnostické metody pro získání vstupních dat


Pro tvorbu vstupních dat jsou nejčastěji využívány tři neinvazivní diagnostické metody:

- Ultrasonografie
- Počítačová tomografie
- Nukleární magnetická rezonance

Každá z těchto metod má své kladné a záporné stránky, vycházející z fyzikálního principu dané metody. **Ultrasonografie** je diagnostická metoda založená na využití a registraci ultrazvuku o kmitočtovém rozsahu mezi 2MHz-18MHz. Princip této metody spočívá ve fyzikálních vlastnostech tkáně, kdy různé typy měkkých a tvrdých tkání mají různě velkou akustickou impedanci, která je odvozena od rychlosti průchodu ultrazvuku tkání. Tato rychlost se pohybuje okolo 1540m/s a mění se s typem tkáně. Informace o změně typu tkáně získáváme díky částečnému odrazu ultrazvuku na rozhraní dvou tkání s rozdílnou akustickou impedancí. Tato diagnostická metoda má několik zobrazovacích módů, mezi nejčastější patří tzv. B-mode v dvourozměrném zobrazení, ve kterém můžeme vidět výřez oblasti. Nejčastěji se s tímto vyšetřením můžeme setkat u vyšetřování vyvíjejícího se plodu, kde se používá k určení například vývojových vad, či anomálií plodu a kontroluje se ním správný vývoj plodu. Pro získání 2D obrazu se používají speciální sondy, které dokážou směřovat ultrazvukové vlnění potřebným směrem a následný post-processing dokáže rekonstruovat 2D obraz. Abychom mohli získat trojrozměrná data, je nutné získat více těchto 2D řezů a mít informace o jejich vzájemné poloze. Toho lze dosahovat několika způsoby:

- použitím zařízení s řízeným posunem sondy nad sledovanou oblastí
- použití běžné sondy doplněné o snímač polohy
- použití jednorozměrné řady s úhlovým vychylováním (manuálním, mechanickým nebo elektronickým)
- použití dvojrozměrné řady (matice) měničů


Nejnovější a nejvíce používaný přístup je použití dvourozměrné řady měničů, díky vícenásobnému snímání a velice rychlému post-procesingu jsme schopni vytvořit trojrozměrný obraz, který navíc můžeme sledovat v reálném čase. Protože se k prostorovým informacím přidává i informace o čase nazývá se tento typ zobrazení jako 4D sonograf. 3D zobrazení bylo dalším logickým vývojovým stupněm ultrasonografického zobrazení tkání a při vývoji byly vytvářeny různé přístupy, jak je popsáno v pramenech [19]-[25]. Mezi prvními trojrozměrnými zobrazovacími technikami byla vyvinuta metoda multiplanární rekonstrukce (MPR).[26] Tato metoda se používá dodnes. Nešlo zde přímo o tvorbu trojrozměrných polygonálních modelů, ale metoda slouží k prostorové orientaci vyšetřujícího lékaře, které mu umožňuje přesnější popis diagnózy. Jedná se o jakýsi přechod mezi 2D a 3D obrazem. Zobrazení MPR vytváří vizuální zobrazení tkání ve třech základních rovinách příčné, podélné a tzv. koronální (rovnoběžná s rovinou těla). Právě díky koronální rovině dostává lékař nové informace o struktuře tkáně. Vyšetřujícím lékařem je vždy zvolena jedna aktivní rovina, ve které se může pohybovat jednotlivými řezy. Ostatní roviny se dopočítávají podle této aktivní s tím, že vyšetřující lékař může volit bod vzájemného průniku všech tří rovin. Na obr. 3.2 můžete vidět zobrazení pomocí MPR. Čerpáno z [26].



Obr. 3.2: MPR zobrazení Hill-Sachsůva defektu hlavičky humeru [26]

Dalším vývojovým stupněm bylo vytvoření trojrozměrného modelu objektu. Vlastní postup je obdobný jak je popsáno na blokovém schématu na obr. 3.1, kde po získání trojrozměrných dat je nutná segmentace v jednotlivých řezech. V moderních sonografických systémech se využívá elektronického pera, pomocí kterého vyšetřující lékař označí oblast, kterou potřebuje vysegmentovat. Tento postup je označován jako určení souboru dat. Na základě tohoto vzoru v určené vrstvě je tkáň segmentována i v ostatních řezech, ve kterých je následně zkontrolována vyšetřujícím lékařem. Následný krok odstraní veškerá data, která se nacházejí vně sledované oblasti. Vyšetřující lékař tak získá trojrozměrný objekt, který lze následně pomocí postprocesingu dále upravovat. Jedná se o přiblížení, vyhlazení objektu, změna jasu atd. Už z principu, z kterého ultrasonografie vychází je zřejmé, že se používá v té oblasti, kde se jedná o velice jasný přechod tkání s výraznou změnou impedance, protože v těchto případech se vytvoří dostatečně jasný a kontrastní přechod jasu v zobrazovaných datech.

První oblasti použití 4D ultrasonografie jsou různá vyšetřování cyklických útvarů, ganglií, hematomů, zapouzdřených hematomů, zvýšené náplni kloubů, či poúrazových procesů a v neposlední řadě do této skupiny vyšetření patří i vývoj plodu (plodová voda). Tato skupina se vyznačuje právě velice nízkou akustickou impedancí, a proto je jasně zřetelná v kontrastu s okolní tkání. Druhá skupina je přesně opačná k té první, tedy tkáň kde je vysoká akustická impedance, do této oblasti lze zařadit tříštivé zlomeniny kostí, nebo při vyšetřování infektů a neoplasmat alterujících kostěný povrch.



Obr. 3.3: Prostorová rekonstrukce kostěného povrchu tříštivé zlomeniny

V této oblasti je 4D ultrasonografie na stejné úrovni jako následující dvě diagnostické neinvazivní metody (CT a NMR), jak je v [26]. Jak je popsáno v předchozí části práce, je tato práce zaměřena zvláště na temporomandibulární kloub. Ultrasonografie se také pro tuto oblast používá, ale pouze v 2D režimu v reálném čase, kdy je vyšetřující lékař schopen z obrazu rozpoznat pohyb disku, avšak jedná se o nedostupnou oblast, kde je velice obtížné správně nasměrovat dvourozměrnou sondu. V této oblasti proběhla konzultace s lékaři, kdy bylo navrženo měřit pomocí sondy z oblasti ústní dutiny, ale výsledné pokusy ukázaly, že

výsledky nepřinesly kýžené zlepšení. Z těchto důvodů bylo upuštěno od této diagnostické metody a zaměřil jsem se na jiné metody.

Druhou neinvazivní diagnostickou metodou je **počítačová tomografie** (CT-computed tomography). Princip této diagnostické metody spočívá ve vytvoření velkého množství snímků z různých úhlů okolo celého těla, z kterých se následně vypočítají prostorové informace uložené do matice reprezentující jednotlivé řezy. Možnost dopočítání prostorové informace je podložena tzv. projekčním teorémem (také nazývaný centrální řezový teorém). Projekční teorém vychází z Radonovy transformace, která je úzce spjata s Fourierovou transformací. Zobecněná definice projekčního teorému říká, že Fourierova transformace projekce N -rozměrné funkce $f(\mathbf{r})$ na m -rozměrný Euklidovský prostor je rovna m -rozměrným řezům N -rozměrné Fourierovy transformace této funkce $f(\mathbf{r})$ skrz počátek ve Fourierovském prostoru, která je rovnoběžná s rovinou projekce. Pomocí operátorů lze teorém vyjádřit následovně [28][29]:

$$F_m P_m = S_m F_N, \quad (3.1)$$

kde F_m je m -rozměrný Fourierův operátor F_N je N -rozměrný Fourierův operátor, P_m je operátor projekce, který provádí projekci N -rozměrné funkce na m -rozměrnou funkci a S_m je operátor řezu, který vybírá m -rozměrný řez počátkem dané funkce.

Pokud $f(x,y)$ je dvourozměrná funkce, pak projekce $f(x,y)$ na osu x je $p(x)$, kde

$$p(x) = \int_{-\infty}^{\infty} f(x, y) dy. \quad (3.2)$$

Fourierova transformace funkce $f(x,y)$ je

$$F(k_x k_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-2\pi i(xk_x + yk_y)} dx dy \quad (3.3)$$

Řez je pak $s(k_x)$

$$\begin{aligned} s(k_x) &= F(k_x, 0) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-2\pi i x k_x} dx dy \\ &= \int_{-\infty}^{\infty} \left[\int_{-\infty}^{\infty} f(x, y) dy \right] e^{-2\pi i x k_x} dx \\ &= \int_{-\infty}^{\infty} p(x) e^{-2\pi i x k_x} dx \end{aligned} \quad (3.4)$$

Jednotlivé dvourozměrné obrazy, ze kterých se počítají řezy, jsou získávány jako zaznamenaná intenzita rentgenového záření, která prošla lidskou tkání [30][31]. Pokles intenzity záření lze popsat Lambert-Beerovým zákonem exponenciálního útlumu:

$$\frac{I_0}{I} = e^{\mu d}, \quad (3.5)$$

kde I_0 je hodnota vstupní intenzity záření, I je hodnota výstupní intenzity, d je tloušťka materiálu a μ je lineární součinitel zeslabení (definován v ČSN ISO 31-10). Stupeň absorpce ionizujícího záření vxelem vztažena k absorpci záření vodou je definována pomocí Housfieldovi stupnice (jednotka HU). Tato hodnota lze spočítat pomocí následujícího vztahu:

$$CT_{\text{číslo}} = 1000 \frac{\mu_{\text{tkáňe}} - \mu_{\text{vody}}}{\mu_{\text{vody}}} \quad [HU], \quad (3.6)$$

Kde $\mu_{\text{vody}} = 0,19\text{cm}^{-1}$ při 73 keV. Stupnice má dva významné body, denzitu vzduchu, která odpovídá hodnotě -1000 HU a denzitu vody [35], která odpovídá hodnotě 0 HU. Denzity vybraných tkání jsou uvedeny v tab. 3.1.

Tab. 3.1: Hounsfieldova stupnice [35]

Objekt	Denzita [HU]
Vzduch	-1000
Tuk	-40 až -120
Voda	0
Starý hematom	+18 až +40
Metastázy	+25 až +50
Nádory	+30 až +50
Čerstvý hematom	+65 až +85
Kompaktní kost	+1000 a více

Právě tento fyzikální princip, pomocí kterého jsou data získávána, vykazuje několik významných nedostatků. Tím prvním je vlastní ionizující záření, které má neblahý vliv na organismus jak pacienta, tak i vyšetřujícího radiologa. Pro tyto neblahé účinky jsou stanoveny jednotlivé maximální dávky ionizujícího záření pro každý orgán. V tab. 3.2 je následně vidět efektivní dávka ionizujícího záření pro dané vyšetření na celé tělo a na konkrétní vyšetřovaný orgán. Maximální dávka pro vyšetřující personál je podle přílohy č.9 vyhlášky č.307/2002 Sb. stanovena na 50mSv/rok a je kontrolována za pomoci dozimetru, u pacientu je stanovena efektivní dávka 1mSv/rok (pro případy, kdy výsledkem výzkumu je pouze zvýšení znalostí, ale bez zaměření na záchranu života nebo prevenci závažných nemocí). Pro případy prevence závažných nemocí, nebo záchranu života jsou hodnoty vyšší.

Tab. 3.2: Hodnoty vstřebaného ionizujícího záření různých CT vyšetření

CT Vyšetření	Typická efektivní dávka na celém těle (mSv)	Zdroj	Typická vstřebaná dávka na daném orgánu (mGy)	Zdroj
Hlava	1-2	[32]	56	[34]
Hrudník	5-7	[32]	13	[34]
Mamografie	0,4	[31]	3	[30][33]
Hrudník, břicho a pánev	9,9	[34]	12	[34]
Angiografie srdce	9-12	[32]	40-100	[33]
Iriografie	15	[30]	15	[33]

Použití ionizujícího záření omezuje použitelnost tohoto typu vyšetření. Z Hounsfieldovy stupnice je patrné, že nejvyšší hodnoty jsou v obrazech budou mít kosti a nejnižší hodnotu jsou naopak místa vyplněná vzduchem (například plíce). Nejdůležitějšími mechanismy interakce RTG záření s vlastními tkáněmi jsou vnitřní fotoelektrický jev a Comptonův rozptyl. Bohužel oba tyto jevy nám přispívají ke zkraslení obrazu. Vlivem těchto mechanismů totiž dochází ke změně směru záření odchýleného od primárního svazku (vnitřní fotoelektrický jev), a dále ke změně vlnové délky záření (Comptonův rozptyl). Vlivem těchto

i dalších činitelů dochází k tvorbě artefaktů ve výstupních obrazech. Hlavními činiteli v tvorbě artefaktů jsou následující příčiny [37]:


- **Fyzikální příčiny** - změna energie svazku, parciální objemový efekt, úbytek fotonů, podvzorkování
- **Vlivy pacienta** – kovové náhrady tkání, pohyb pacienta při vyšetření
- **Technická omezení skeneru**- citlivost detektoru, mechanická nestabilita

Vznikem artefaktů se částečně degraduje informace získaná skenováním. Podle druhu mohou vzniknout na výstupních obrazech tyto typy artefaktů [36][37]:

- **Kruhový artefakt** – vzniká nejčastěji v 3. generaci CT a je způsobena různou citlivostí jednotlivých detektorů ionizujícího záření.
- **Pohybový artefakt** – vzniká úmyslným (pohyb částí těla pacienta) či neúmyslným (tlukot srdce, dýchání) pohybem pacienta při vyšetření.
- **Kovový artefakt** – vzniká přítomností kovových částí uvnitř skenované oblasti. Dochází při něm k extrémní absorpci v místě s kovovým předmětem a tím dojde k výpadkům informací v této oblasti.
- **Aliasingový artefakt** – vzniká nedostatečně nevzorkovanou scénou, kdy dojde k nedodržení Shannonova vzorkovacího teoremu.
- **Pruhový artefakt** – vztahuje se k Lambert-Beerově zákonu popsaného rovnicí (3.5), kde vlivem kvantového šumu dochází k nedostatečnému průchodu oblastmi s velkou vrstvou tkání. K potlačení se využívá adaptivní filtrace.
- **Artefakt částečného objemu** – vzniká působením více struktur na oblast jednoho voxelu.
- **Artefakty vlivem helikální akvizice** – vzniká vlivem nehomogenity distribuce šumu v jednotlivých pixelech obrazu, která se mění v závislosti na z-pozici. Projevuje se střídáním podélných světlých a tmavých pruhů.

Pro odstranění těchto artefaktů byly vyvinuty různé metody, některé založeny na různých typech sekundárních clon (např. Buckyho clona) jiné, které používají různé typy filtrů. Bohužel vždy dojde k určitému zkreslení informace, což nám vnáší nepřesnosti i do výsledných 3D modelů. Využití CT se používá hlavně tam, kde se jedná o tkáně složené z prvků s vyšším atomovým číslem v kontrastu s tkáněmi v nejbližším okolí, hlavně tedy kosti (vysoký obsah vápníku) v kontrastu s měkkými tkáněmi, jako svaly, šlachy (založeny hlavně na uhlíku). Další takovou významnou oblastí využití CT jsou členité struktury například plíce, nebo střeva. CT se však nehodí na vizualizaci měkkých tkání a orgánů, protože v těchto oblastech vykazuje velice slabý kontrast mezi jednotlivými tkáněmi, a tím dochází ke ztrátě informace o hraničních částech jednotlivých tkání a je složité je segmentovat. Hlavní oblastí využití CT je hrudník, kde se jedná hlavně o plicní angiografii, která zobrazuje tepny v oblasti plic a užívá se při diagnostice plicní embolie. Podobně se využívá kardio angiografie v oblasti srdce, kde se sledují koronární tepny. Další důležitou oblastí využití CT je oblast břišní dutiny a pánve. Zde se CT používá v kombinaci s kontrastní látkou (nejčastěji 2% suspenze síranu barnatého) pro vyšetření zánětu slepého střeva, zánětu slinivky břišní, zánětu divertiklu, břišní aortální výduť a ucpaní střeva. V neposlední řadě se CT využívá k zobrazení složitých fraktur končetin, především v oblastech kloubů. Při pohledu na problematiku čelistí a temporomandibulárního kloubu, tak CT zde hraje velký význam v oblasti zubu, čelistí, kloubní hlavy (fossa) a kloubní jamky, avšak nelze ji použít pro modelování kloubního disku, který jak bylo řečeno bývá nejčastější příčinou problémů s temporomandibulárním kloubem. Protože pomocí CT v oblastech, které tu byly vyjmenovány, získáváme velice kontrastní

obraz sledované tkáně (ať už vlivem vysokého atomového čísla prvku tkáně, nebo použitím kontrastní látky) není tolik nutné užití složitých metod zpracování obrazu, jako tomu je u dále popsané MRI. Další výhodou CT je také v porovnání s MRI vyšší prostorové rozlišení pořízených snímků. Na oblast tvorby 3D objektů tkání z řezů CT se zaměřuje mnohem více výzkumných týmů i soukromých firem, než je tomu u tvorby 3D objektů z NMR. V České republice se tomuto tématu věnuje např. tým okolo Doc. Ing. Josefa Kohouta, Ph.D. na Západočeské univerzitě v Plzni, kde vyvíjejí i vizualizační software CTVolRegApp, pomocí kterého je možné vytvářet trojrozměrné objekty, na kterých lze následně provádět různé operace, jakými jsou různá oříznutí, porovnávání, rotace, translace, převzorkování, filtrování (Gaussovo vyhlazení) atd. Tento tým spolupracuje s 2. lékařskou fakultou univerzity Karlovy v Praze s oddělením dětské stomatologie. V této oblasti se jedná o studie čelistí a čelistního kloubu, jak je možné vidět v publikaci [38] což je velice podobná problematika, kterou se zabývá i tato práce. Jak je popsáno ve [38], tak téma tohoto článku se hlavně opírá o počítačovou tomografii, pomocí které je modelována lebka 75 leté pacientky, na které je kontrolován vývoj rozsáhlé susp. radikulární cysty dolní čelisti, dále její odstranění, náhrada části čelisti pomocí implantátu a následná regenerace pacientky. Pro tvorbu 3D modelů byl využit dříve uvedený software CTVolRegApp. Jako zdrojová data byl využit CT snímač s využitím rozšířeného 2D paprsku, sloužícího k určení lokalizace. Pro segmentaci byla využita knihovna ITK (Insight Tool Kit), který pro segmentaci využívá segmentační metody, které jsou podrobněji popsány v pramenu [39]. Na základě použitých segmentačních metod byly vytvořeny masky tkání v jednotlivých řezech a za pomoci diskretní verze metody Marching Cubes byl následně vytvořen polygonální model tkáně. Na obr. 3.4, který je převzat z [38] je vidět výsledek rekonstrukce pomocí programu CTVilRegApp. Jak je vidět jedná se pouze o kostní tkáň, která je u CT velice kontrastní a lze ji z CT řezů snadno vyseparovat.



Obr. 3.4: 3D model z CT v programu CTVilRegApp

Nejmodernější neinvazivní diagnostickou metodou je **magnetická rezonance(MR)**, která je často označována také jako **nukleární magnetická rezonance(NMR)**. Princip této metody spočívá ve využití velice silného magnetického pole (řádově 0,1 Tesla až 3 Tesla), které usměrní magnetický moment jednotlivých protonů obsažených v tkáních vyšetřovaného pacienta ve směru magnetického pole. Tyto protony se však nechovají staticky, ale

zachovávají si svůj rotační pohyb nazývaný spin. Kromě spinu provádí ještě jeden druh pohybu tzv. precesi. Jedná se taktéž o rotační pohyb, kdy rotující proton sám ještě provádí pohyb okolo pomyslné osy, která je určena silokřivkou magnetického pole zevního magnetu. Frekvence tohoto precesního pohybu se nazývá Larmorova frekvence, která závisí na dvou faktorech. V první řadě na gyromagnetickém poměru atomového jádra a dále pak na intenzitě vnějšího magnetického pole (přímo úměrně). Matematickým vyjádřením tohoto vztahu je Larmorova rovnice definovaná [40]

$$\omega_0 = \gamma B_0, \quad (3.7)$$

kde ω_0 je Larmorova frekvence, γ představuje gyromagnetický poměr (pro vodíková jádra činí 42,577 MHz/T) a B_0 představuje intenzitu magnetického pole vyjádřenou v jednotkách magnetické indukce. Protony v tkáni se vlivem vnějšího magnetického pole uspořádají svoje rotační osy rovnoběžně s průběhem siločar, avšak jejich magnetický moment nemusí být orientován ve směru magnetického momentu vnějšího magnetického pole. Protože však je pro protony energeticky méně náročné mít souhlasně směřován magnetický moment jako vnější pole, je statisticky dokázáno, že větší počet protonů má magnetický moment souhlasně orientován se směrem momentu vnějšího magnetického pole. Tyto protony jsou označovány jako paralelní protony. Podle příkladu v [40] pokud máme 1 000 000 protonů s opačným magnetickým momentem jako je vnější magnetické pole, potom paralelních protonů je statisticky 1 000 006. Jak je z příkladu patrné, tak z celkového počtu protonů nám celkový magnetický moment ovlivňuje pouze zlomek z nich, což má ve výsledku velký vliv na přesnost měření. Tento rozdíl v magnetickém momentu je složité změřit, protože se jedná jen o velice malou změnu, a proto se přešlo k metodě, kdy se tyto protony vybudí. K tomu se používá další zdroj nyní střídavého magnetického pole, který má stejnou frekvenci jako je Larmorova frekvence. Tím se dodá energie protonům, které nám vytváří zvýšení magnetického momentu (v uvedeném případě jich je 6). Dodáním energie přejdou některé z nich do opačného směru magnetického momentu než je vnější magnetické pole. Druhým efektem působení střídavého magnetického pole je, že všechny buzené protony zesynchronizují svůj precesní pohyb, čímž dojde k změně magnetického momentu v příčném směru. Po vypnutí zdroje střídavého magnetického pole protony opět ztrácí energii a vracejí se do původních poloh magnetického momentu, který je energeticky méně náročný. Opět dojde ke zvýšení magnetického momentu v podélném směru a k limitnímu přiblížení příčné magnetizace k nule. Čas, kdy se podélná magnetizace vrátí k původním hodnotám (ve skutečnosti se měří 63% původní velikosti [40]) se nazývá doba relaxace a značí se $T1$. Doba potřebná k poklesu magnetického momentu v příčném směru na 37% se značí jako $T2$. Tyto časy přepočítané na úroveň šedi se značí jako $T1$ a $T2$ vážení [40]. Pro tkáň se hodnoty $T1$ pohybují v rozmezí 300ms-2000ms a hodnoty $T2$ v rozmezí 30ms-150ms. Další možností měření je tzv. protonová hustota (proton density), která vychází z měření poměrných zastoupení protonů v jednotlivých tkáních. Princip NMR umožňuje nastavit více parametrů, které nám ovlivňují vlastní měření, než je tomu u CT, kde se jedná pouze o propustnost tkáni pro rentgenové záření. Změny parametrů souvisejí s energií, kterou protonům dodáme pomocí střídavého magnetického pole. Můžeme totiž měnit čas, po který střídavé magnetické pole necháme působit a dále můžeme měnit sílu tohoto magnetického pole a tím velikost energie, kterou protonům poskytneme (ovlivní nám počet protonů, které přejdou do antiparalelní polohy). Tyto parametry nám následně ovlivňují časy $T1$ a $T2$. V tomto směru nám NMR může poskytnout mnohem více informací, protože různými parametry se můžeme zaměřit na různé vlastnosti jednotlivých tkání.

Jak je patrné z popisu principu na výsledných naměřených datech se podílí jen malé procento protonů obsažených v tkáni a zároveň je dané měření v porovnání s ostatními


metodami velice pomalé, což je patrné z hodnot časů $T1$ a $T2$. Od těchto časů se odvíjí i doba vyšetření pacienta NMR tomografem, která se samozřejmě odvíjí od vyšetřované části těla a pohybuje se v rozmezí 10 minut až více jak 45 minut. Další nevýhodou jsou vedlejší účinky při přítomnosti kovových materiálů v těle pacienta, které se vlivem magnetického pole mohou zahřát a ohrozit tak pacienta. Nejedná se jen o kovové náhrady kostí nebo kloubů, ale hlavně např. o kardiostimulátory, nebo kochleární implantáty, které jsou mnohem vyšším nebezpečím pro pacienta a kvůli kterým není možné vyšetření NMR provést. Dále si musíme uvědomit i ekonomickou stránku použití NMR, kdy jak pořizovací cena přístroje, tak i provozní náklady jsou velmi vysoké. To se odráží i v počtu vyšetření v porovnání s CT a Ultrasonografií. V neposlední řadě při porovnání s CT se v MRI obrazech vyskytují mnohem častěji artefakty, které snižují kvalitu výsledného obrazu. Tyto artefakty lze rozdělit podle druhu vzniku na [41][42]:

- **Artefakt chemického posunu** – Tento artefakt vzniká vlivem rozdílné rezonanční frekvence vody v tkáních, svalech a tuku. Tento rozdíl v rezonančních frekvencích způsobí chybu v prostorové informaci, která se projeví v obraze jako absence signálu na rozhraní voda-tuk, nebo naopak dojde ke zvýšení signálu a tím vznikne superpozice signálu vody a tuku.
- **Aliasingový artefakt** – Stejně jako u CT i v MRI může vzniknout aliasingový artefakt. Často je v literatuře označován jako wrap-around artefakt a vzniká v případech, kdy je rozměr FOV (Field Of View) menší než je vyšetřovaná oblast těla. Tento artefakt se projeví na obraze tak, že ta část, která je mimo oblast FOV se superponuje na opačné straně MRI obrazu.
- **Susceptibilní artefakt** – Tento typ artefaktu vzniká vlivem mikroskopických výkyvů v intenzitě magnetického pole, což je nejčastěji způsobeno přítomností rozhraní látek s rozdílnou susceptibilitou. V MRI obraze se susceptibilní artefakt projevuje prostorovou distorzí okolních tkání v kombinaci se světlými a tmavými nesourodými oblastmi.
- **Artefakt černého lemu** – V literatuře je označován také jako Black Boundary artefact. V MRI obrazech se projevuje černou okrajovou linií v oblasti rozhraní svaly-tuk. Artefakt vzniká zobrazením tuku i vody a při jeho rekonstrukci zde vznikne ostré zobrazení přechodu. To sice vytyčí ostrý okraj svalové tkáně, avšak nemá spojitost se skutečnou tkáňovou strukturou v dané oblasti.
- **Pohybový artefakt** – MRI mnohem více jak CT je citlivé na pohybové artefakty. Tento artefakt je zapříčiněn buď pohybem orgánů (plíce, srdce), nebo vlastním pohybem pacienta během akvizice dat. V MRI datech se projeví jako světlý šum, nebo střídání hustot. Velice těžko se tento artefakt dá v obraze potlačit a pro dlouhé měřicí časy je velice obtížné udržet pacienta v jedné poloze. Tento artefakt se opravdu objevuje v obrazech velice často. U orgánů, kde předem víme, k jakým pohybům dochází, můžeme tento artefakt odstranit. Často je však tento artefakt způsoben nepředvídatelným pohybem pacienta, a to i ve více směrech.
- **Gibbsův artefakt** – V literatuře také označován jako trunkační artefakt a projevuje se drobnými světlými, nebo tmavými liniemi, které jsou rovnoběžné s oblastí s prudkou změnou intenzity. Můžeme se s těmito artefakty setkat například u mozkomíšního moku v kontrastu k tmavé míše na $T2$ vážených obrazech. Tento artefakt je způsoben Gibbsovým fenoménem od čehož je odvozen i název.
- **Zipový artefakt** – Tento artefakt není příliš obvyklý. Vzniká vlivem nehomogenity pole způsobené nejčastěji vnějším rušením. V obraze se tento typ artefaktů vyznačuje jako přerušované linie kolmé na osu frekvence.

- **Artefakt překrytí vrstev** – K tomuto jevu dochází při použití více-objemové (multi-stack) technice měření. Při tomto měření může dojít k tomu, že se měří více objemů pod různými úhly na tkáni, která se v daném místě překrývá. Dojde totiž k tomu, že v místě artefaktu se nacházely spiny, které byly saturovány již druhou vrstvou. V obraze se tento artefakt projeví ztrátou informace v daném místě překryvu vrstev.

Samozřejmě jsou tyto nevýhody, které zde byly zmíněny vykompenzovány výhodami, které MRI oproti ostatním diagnostickým metodám má. Hlavní výhoda, která je nejvýznamnější v porovnání s CT to, že NMR vychází z fyzikálního principu, při kterém se nevyužívá žádného škodlivého ionizujícího záření. Proběhlo mnoho studií, při kterých byly testovány negativní účinky magnetické rezonance, ale žádné nebyly prokázány. Druhou velkou výhodou je zobrazování všech tkání v měřené oblasti a to jak tvrdých, tak i měkkých. Podobně jak je tomu u CT, můžeme i u MRI využít pro zpřesnění měření některých tkání kontrastní látku.

I v oblasti MRI existují algoritmy pro tvorbu 3D modelu a v mnohém jsou podobné těm, které se využívají pro tvorbu 3D modelu u CT. Oproti CT má však MR menší kontrast jednotlivých tkání, což je do jisté míry zapříčiněno malým počtem protonů, které se na vlastním měření podílejí. Bohužel u MRI nemáme přesně stanovenou stupnici pro přepočet do hodnot šedi jako je Hounsfieldova stupnice u CT, což je dáno tím, že máme větší počet možností jak měřit danou tkáň (T_1 , T_2 , PD atd.), které mohou navíc nabývat různých hodnot v závislosti na parametrech vstupního magnetického pole. Právě tohle je hlavní příčina toho, že většina vývojových týmů se zaměřuje na CT, kde máme téměř vždy normovaná vstupní data. V oblasti tvorby 3D modelu z MRI byl mezinárodně uznávaným časopisem Scientific Computing & Instrumentation Magazine v letech 2000 a 2002 zvolen komerční software 3D-Doctor od společnosti ABLE SOFTWARE. V roce 2004 vyhrál tento software prestižní cenu Frost & Sullivan za excelentní výzkum v oblasti zpracování biomedicínckých dat. Jedná se o špičku v oboru 3D zpracování různorodých biomedicínckých dat. Výstup z tohoto softwaru při zpracování MRI obrazu je na obrázku obr. 3.5.



Obr. 3.5: 3D model tumoru v mozku pomocí programu 3D DOCTOR
(zdroj:www.ablesw.com/)

3.2 Filtrace obrazu

Ze všech popsaných neinvazivních diagnostických metod získáváme trojrozměrná data, která jsou složena z dvourozměrných řezů, které na sebe navazují. Protože jednotlivé řezy obsahují dvourozměrná data, která se strukturou a vlastnostmi velice podobají kamerou získaným obrazovým datům, je možné použít metody, které se pro zpracování těchto obrazů používají. Pro rozhodování o správné volbě metody na zpracování obrazu je nutné zhodnotit velké množství parametrů. Mnoho parametrů obrazu je matematicky vyjádřitelných, ale některé je nutné zhodnotit subjektivně (pohledem). Z parametrů, které se dají vyjádřit matematicky jsou nejvýznamnější tyto:

- kontrast
- odstup signálu od šumu
- variace obrazového signálu
- ostrost hran

Jako první je definován parametr **kontrast**. Tento parametr je vyjádřením poměru rozdílu jasu zájmové oblasti a jasu v jejím okolí k průměrnému jasu obrazu [44] a dá se vyjádřit vztahem:

$$k = \frac{I - I_p}{I}, \quad (3.8)$$

kde I je průměrná hodnota jasu obrazu v místě snímaného objektu a I_p je průměrná hodnota jasu obrazu v pozadí. Pro případy, kdy velikosti ploch pozadí a zájmové oblasti jsou si velice blízké, lze aplikovat vztah:

$$k = \frac{I_{\max} - I_{\min}}{I_{\max} + I_{\min}} \quad (3.9)$$

Kontrast nám určuje nakolik je oblast zájmu, v případě biomedicínckých dat oblast s tkání, jasově rozdílná od okolní tkáně. Tento parametr je velice vypovídající o možnostech segmentace tkáně od okolí.

Obecně nejčastěji užívaným parametrem k posouzení kvality signálu je **odstup signálu od šumu**, který patří k základním parametrům stanovující obsah šumu v obraze. U MRI obrazu je SNR počítán jako druhá mocnina průměrné intenzity z vybrané oblasti vztažené k druhé mocnině změny Gaussova šumu :

$$SNR = 10 \log_{10} \left(\frac{I_{\text{mean}}^2}{\sigma^2} \right), \quad (3.10)$$

kde I_{mean} je průměrná hodnota intenzity I v homogenní oblasti zájmu a σ je standardní odchylka šumu v oblasti zájmu. Pro I_{mean} platí [46]

$$I_{\text{mean}} = \frac{1}{MN} \sum_{i=0}^M \sum_{j=0}^N I_{(i,j)}. \quad (3.11)$$

Pro vlastní stanovení obsahu šumu v obraze existuje mnoho dalších definic jak je patrné z pramene [28]. Šum je parametr, který nám nejvíce ovlivňuje jak vlastní segmentaci tkáně, tak i ostatní součásti procesu tvorby trojrozměrných modelů a může nám neblaze ovlivnit kvalitu výsledného modelu. O typech šumů a způsobech používaných k jejich odstranění se dá napsat zvláštní práce.

Pro vyhodnocování kvality obrazu se můžeme setkat také s parametrem, který určuje poměr **kontrastu k šumu** [45]. Tento parametr popisuje kombinaci poměru signálu k šumu s kontrastem dvou oblastí A a B a udává nám rozdíl poměrů SNR v těchto oddělených oblastech:

$$CNR = SNR_A - SNR_B [\text{dB}]. \quad (3.12)$$

Pro posouzení globální ostrosti obrazu se využívá metody, která se nazývá **variace obrazového signálu**. Tato metoda vychází z předpokladu, že obrazy jsou vysoce korelovaný signál, u kterého existuje významný vztah mezi na sobě navazujícími vzorky. Vyjdeme-li z tohoto předpokladu, mělo by být možné předpovídat hodnoty navazujících vzorků s určitou přesností ze sady předchozích vzorků. Budeme-li pro predikci aktuálního vzorku pixelu $u(x,y)$ využívat pouze předchozího vzorku pixelu $u(x, y - 1)$, potom lze rozdíl mezi predikovanou a skutečnou hodnotou pixelu dána vztahem:

$$q(x, y) = u(x, y) - u(x, y - 1). \quad (3.13)$$

Celkovou variaci v obraze lze následně vyjádřit vztahem

$$\sigma_P^2 = \frac{1}{M(N-1)} \sum_{x=1}^M \sum_{y=1}^{N-1} [q(x, y) - \bar{q}]^2, \quad (3.14)$$

kde \bar{q} představuje průměrnou hodnotu z $q(x,y)$. Význam této metody spočívá v posouzení celkové ostrosti obrazu, protože jak je popsáno v [52] lze odvodit, že variace u ostrého obrazu je zřetelně vyšší, než je tomu u rozmazaného obrazu.

Výše popsané vlastnosti obrazu blízko souvisejí s jeho kvalitou, protože pro vstup je žádoucí mít co nejkvalitnější data. Bohužel v reálných podmínkách se velice vzdalujeme od ideálních dat, a proto je nutné předzpracování obrazu, což je nejčastěji řešeno pomocí filtrace. Samotná filtrace obrazu by vystačila na samotnou práci, proto se zde budeme zabývat pouze technikami, které přináší zlepšení pro MRI obrazy čelistního kloubu a patří mezi pokročilejší techniky. Protože v oblasti technik filtrace se v poslední době nejvíce začala prosazovat metoda prahování koeficientů vlnkové (waveletové) transformace, budeme se v oblasti filtrace zabývat hlavně touto technikou. Vlnkové transformace je obdobou krátkodobé Fourierovy transformace, ale oproti ní má určité vlastnosti, které umožňují vytvářet mnohem účinnější filtry. Vlnková transformace nám umožňuje analýzu nestacionárních signálů, u kterých nám umožňuje získat dvourozměrnou funkci času a měřítka. Oproti Fourierově transformaci se zde využívá časově omezené funkce ve tvaru vlnky. Tato funkce se nazývá mateřská vlnka, která musí splňovat podmínky blíže popsáné v [49]. Obecně základními vlastnostmi, které musí mateřská vlnka splňovat, jsou dány vztahy

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0, \quad (3.15)$$

$$\int_0^{+\infty} \frac{|\Psi(\omega)|^2}{\omega} d\omega < \infty, \quad (3.16)$$

kde $\Psi(\omega)$ je Fourierův obraz $\psi(t) \in L^2(\mathbf{R})$. Základní vztah pro odvození mateřských vlnek vychází z tvaru

$$\psi_{\lambda, \tau}(t) = \frac{1}{\sqrt{\lambda}} \psi\left(\frac{t - \tau}{\lambda}\right), \quad (3.17)$$

kde $\lambda, \tau \in \mathbf{R}, \lambda \neq 0$, t je čas. Parametr λ představuje dilataci a parametr τ translaci. První člen rovnice slouží k zachování energie při změně měřítka. Báze waveletových funkcí by měla být ortogonální. Základní vlnková transformace pro spojité signály s konečnou energií $f \in L^2(\mathbf{R})$ je definována vztahem:

$$Wf(\tau, \lambda) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{\lambda}} \psi^*\left(\frac{t - \tau}{\lambda}\right) dt, \quad (3.18)$$


kde ψ^* označuje číslo komplexně sdružené a výsledek vzorce je dvourozměrná funkce $Wf(\tau, \lambda)$, která se nazývá vlnkové koeficienty. Uvedený základní tvar waveletové transformace pro spojité 1D signál ve spojitém čase se dá rozšířit do tvaru 2D dyadické waveletové transformace s diskretním časem, která je označována jako 2D-DTWT a je užívána pro analýzu obrazu. Odvození DTWT z vzorce (3.18) je v literatuře [53]. 1D Dyadická vlnková transformace s diskretním časem je nejčastěji řešena bankou filtrů a lze definovat jako diskretní konvoluce, kde i značí index vzorků v čase

$$y(\mathbf{m}, \mathbf{n}) = \sum_{i=-\infty}^{\infty} h_m(i) x(2^m \mathbf{n} - i). \quad (3.19)$$

Zjednodušeně lze rozdíl mezi 1D a 2D waveletové transformací popsat tak, že u 2D vlnkové transformace dochází k rozkladu signálu nejprve po řádcích a následně po sloupcích podobně jako je to u 1D a 2D Fourierovy transformace. Výsledkem rozkladu obrazu podle 2D-DTWT vzniknou čtyři části:

- HL – vertikální obraz,
- LH – horizontální obraz,
- HH – diagonální obraz,
- LL – obraz vzniklý z dolních frekvenčních pásem.

Následný rozklad obrazu v další úrovni probíhá pouze u LL předchozího stupně. Grafický rozklad obrazu lze znázornit viz. obr. 3.6.



Obr. 3.6: Blokové schéma jednoho stupně dekompozice obrazu 2D DTWT

Filtrace pomocí waveletové transformace je závislá na několika faktorech. V první řadě je to volba mateřské vlnky. V současné době existuje kolem 400 mateřských vlnek. Zvolení mateřské vlnky ovlivňuje výsledek filtrace. Ne všechny vlnky vykazují pro různé typy šumu stejně dobré výsledky. Prakticky se volba mateřské vlnky provádí tak, že nejprve se zvolí okruh mateřských vlnek, které jsou použitelné pro danou aplikaci. Například nejznámějšími používanými symetrickými mateřskými vlnkami jsou vlnka typu mexický klobouk a Morletova vlnka. Tyto vlnky však nejsou ortogonální a nelze je proto použít pro DWT. V [46] je popsáno využití tří rodin mateřských vlnek, jejichž vlastnosti jsou popsány v tab. 3.3.

Tab. 3.3: Přehled vlastností třech základních mateřských vlnek

	Haarova	Daubechiesové	Coiflet
Ortogonální	Ano	Ano	Ano
Biortogonální	Ano	Ano	Ano
Symetrická	Ano	Ne	Ne
DWT	Ano	Ano	Ano
CWT	Ano	Ano	Ano

Vlastní filtrace pomocí DWT funguje na principu prahování waveletových koeficientů, vzniklých dekompozicí obrazu pomocí mateřské vlnky[46]. Základními typy prahování je měkké a tvrdé. Měkké prahování je dáno vztahem:

$$\hat{c}[k] = \begin{cases} \text{sgn}(c[k])(|c[k]| - T) & \text{pro } |c[k]| \geq T, \\ 0 & \text{pro } |c[k]| < T, \end{cases} \quad (3.20)$$

kde $\hat{c}[k]$ jsou detailní koeficienty po aplikovaném měkkém prahování a $c[k]$ jsou koeficienty před aplikovaným prahováním. Parametr T značí hodnotu prahu a sgn . je znaménková funkce, která je dána vztahem:

$$\text{sgn} = \begin{cases} 1 & \text{pro } c[k] > 0 \\ 0 & \text{pro } c[k] = 0 \\ -1 & \text{pro } c[k] < 0 \end{cases} \quad (3.21)$$

U tvrdého prahování se nulují hodnoty waveletových koeficientů, které mají hodnotu nižší, než je hodnota prahu T . Hodnoty vyšší než je zvolený práh ponechá nezměněny. Tvrdé prahování lze popsat vztahem:

$$\hat{c}[k] = \begin{cases} c[k] & \text{pro } |c[k]| \geq T, \\ 0 & \text{pro } |c[k]| < T. \end{cases} \quad (3.22)$$

V článku [46] jsou ještě popsány poloměkké prahování, které používá dva prahy T_a a T_b pro které platí $T_a < T_b$ a je dán vztahem:

$$\hat{c}[k] = \begin{cases} c[k] & \text{pro } |c[k]| \geq T_b, \\ \text{sgn}\left(c[k] \frac{(|c[k]| - T_a)T_b}{T_b - T_a}\right) & \text{pro } T_a \leq |c[k]| < T_b, \\ 0 & \text{pro } |c[k]| < T_a. \end{cases} \quad (3.23)$$

a hybridní prahování, které představuje kompromis mezi měkkým a tvrdým prahováním. Hybridní prahování je dáno vztahem:

$$\hat{c}[k] = \begin{cases} c[k] - \frac{T^2}{c[k]} & \text{pro } |c[k]| \geq T, \\ 0 & \text{pro } |c[k]| < T. \end{cases} \quad (3.24)$$

Volba typu prahování má sice vliv na hloubku filtrace obrazu, ale pro všechny typy je nutné odhadnout práh T . Volba optimálního prahu je jedna z nejdůležitějších částí filtrace pomocí vlnkové transformace. Pokud je práh příliš nízký, potlačení šumu je neefektivní, naopak pokud práh je zvolen příliš velký dojde ke ztrátě důležitých informací z obrazu. Nejčastěji užívanou technikou volby optimálního prahu je tzv. *univerzální technika* definována v [49] jako

$$T = \sigma \sqrt{2 \ln(M \cdot N)} \quad (3.25)$$

kde M a N značí výšku a šířku obrazové matice a σ značí směrodatnou odchylku šumu v obraze, který může být odhadnut za pomoci teoremu odvozeného Donohem a Johnsonem [51]. Využívá se zde statistického modelu vypočítaného jako medián absolutních hodnot počítaný z detailních koeficientů prvního stupně dekompozice poděleného hodnotou 0,6745.

$$\sigma = \frac{\text{MAD}(c_D)}{0.6745} \quad (3.26)$$

Funkce MAD je definována jako:

$$MAD((c_i)_i) = \text{median}(|c_i|). \quad (3.27)$$

Další možností odhadu hodnoty prahu může být pomocí Bayesianova odhadu popsaného v [47] a definovaného následujícím vztahem:

$$T = \frac{\sigma_{\text{sum}}^2}{\sigma_s^2}, \quad (3.28)$$

kde standardní odchylku signálu σ_s lze odhadnout za pomoci následujícího vztahu

$$\sigma_s^2 = \sigma_x^2 - \sigma_{\text{sum}}^2 = \frac{\sum_i c(i)}{M \cdot N} - \sigma_{\text{sum}}^2 \quad (3.29)$$

Jiný přístup k filtraci koeficientů je využití techniky Wienerova filtru popsané v [48]. Tato technika je definována jako násobení i -tého vlnkového koeficientu s faktorem utlumu $\alpha(i)$:

$$\hat{c}(i) = \alpha(i) \cdot c(i). \quad (3.30)$$

kde koeficient útlumu je odvozen podle vztahu:

$$\alpha(i) = \left[\frac{|c(i)|^2 - \sigma^2}{|c(i)|^2} \right], \quad (3.31)$$

kde odhad směrodatné odchylky šumu může být vypočítána podle vztahu (3.29). V [46] jsou porovnány výše popsané techniky užívané při waveletové filtraci na obrazech z Magnetické rezonance. Výsledky jsou v tab. 3.4.

Tab. 3.4: Výsledky SNR v [dB] pro různé typy vlnek a prahování [46]

		Haar	Daubechiesové	Coiflet
Bayesiho odhad prahu	Tvrdé	26,1	26,0	21,9
	Měkké	35,7	34,9	31,4
	Poloměkké	35,5	34,7	30,8
	Hybridní	33,5	32,9	28,0
Univerzální práh	Tvrdé	33,6	32,6	33,1
	Měkké	37,4	36,4	36,8
	Poloměkké	37,3	36,4	36,8
	Hybridní	37,1	36,2	36,7
	Wienerův filtr	36,7	35,7	36,3

3.3 Segmentační metody

Díky předzpracování získáme pouze obraz, který vykazuje lepší vlastnosti, než původní vstupní data. Nyní je nutné nalézt v obraze jednotlivé objekty, které reprezentují jednotlivé tkáně. Tento proces se nazývá segmentace obrazu. V oblasti segmentace biomedicínckých

obrazů se stále velice prosazuje **manuální segmentace**, která je sice nejjednodušší, ale zároveň pro velký objem dat je nejpracnější. Protože je vždy prováděna expertem patří v rámci maloobjemových dat k nejpřesnější segmentační metodě, ke které se snažíme automatickými metodami přiblížit. V řadě softwarů se využívá označování za pomoci po částech lineární křivce tvořené body a úsečkami, kde přesnost určuje počet použitých bodů. Plně automatické segmentační metody se v oblasti biomedicínckých dat doposud využívají jen velice málo. Jednak nelze s jistotou zaručit správnost segmentace za jakýchkoliv podmínek a dále je to dáno i nedůvěrou odborníků z oblasti medicíny k těmto algoritmům. Z těchto důvodů se téměř vždy využívá poloautomatických segmentačních metod, kde je možná korekce výsledku.

Nezákladnější a zároveň nejrychlejší segmentační metoda se nazývá **prahování** [28]. Předpokladem pro segmentaci pomocí této metody je, že objekt vykazuje odlišné jasové vlastnosti, než jeho okolí. Díky tomu lze stanovit oddělovací hranici (případně i více hranic), které objekt jasově oddělí od okolí. Většinou však objekt obsahuje velké množství jasových složek, které jsou totožné se složkami v jeho okolí. Dochází tak často buď k fragmentaci objektu, nebo nedojde k oddělení od okolního prostředí. Matematicky se jedná o transformaci obrazu f do binární podoby g pomocí prahu T což jde popsat takto:

$$g(i, j) = \begin{cases} 1 & \text{pro } f(i, j) \geq T \\ 0 & \text{pro } f(i, j) < T \end{cases} \quad (3.32)$$

Pro danou metodu je zásadní stanovení prahu, a proto se mnoho literatury zabývá jeho automatickým stanovením na základě analýzy vlastností obrazu. Nejčastěji se práh hledá z histogramu obrazu. Nejjednodušší metody vycházejí z hledání lokálních minim mezi dvěma špičkami, které charakterizují objekty, které se snažíme od sebe oddělit. Hlavním problémem této metody je v šumu, který se projevuje v histogramu, zakrývá lokální minimum a ani výsledné nalezení prahu nemusí být optimální. Pokročilejší technikou, která vychází z prahování je **shluková analýza**. Jedná se o vícerozměrnou statistickou metodu, kde se každý bod obrazu zařadí do jedné z několika skupin podle stanovených prahů tak, aby hodnota jeho intenzity byla bližší jedné, nebo druhé průměrné hodnotě intenzit pozadí, popřípadě segmentovaného objektu. Vyjdeme-li z toho, že obraz je dvourozměrná funkce f a zvolíme-li si počáteční práh T , potom můžeme určit střední hodnotu pod tímto prahem $\mu_B(T)$, která nám bude reprezentovat pozadí a střední hodnotu intenzit $\mu_O(T)$, která nám bude reprezentovat objekt. Segmentace potom spočívá v nalezení prahu T , tak abychom všechny intenzity, které se blíží blíže střední hodnotě pozadí, přiřadili pozadí a opačně intenzity, které se více blíží střední hodnotě objektu přiřadili objektu podle vztahu

$$\begin{aligned} \forall f \geq T : |f - \mu_B(T)| &> |f - \mu_O(T)|, \\ \forall f < T : |f - \mu_B(T)| &< |f - \mu_O(T)|. \end{aligned} \quad (3.33)$$

Počáteční průměrná hodnota intenzity pozadí se nejčastěji určuje z krajních rohů, které jsou s největší pravděpodobností body pozadí, a počáteční průměrná hodnota popředí se nejčastěji určuje ze čtyř náhodně vybraných bodů uvnitř obrazu. Práh T se vypočítává jako průměrná hodnota středních intenzit pozadí a objektu:

$$T = \frac{\mu_B(T) + \mu_O(T)}{2}. \quad (3.34)$$

S každým novým prahem T se určí i nové hodnoty středních intenzit $\mu_O(T)$ a $\mu_B(T)$. Celý postup se opakuje do doby, kdy hodnota prahu konverguje.

Popsaný princip popisuje situaci, kdy oddělujeme pouze jeden objekt od pozadí. Pokud však tohle zobecníme a vyjdeme z předpokladu, že máme soubor pozorování, který je dán $(x_1, x_2, x_3, \dots, x_n)$, kde každé pozorování je d -rozměrný reálný vektor označující pozice shluků bodů v obraze, potom algoritmus shlukové analýzy se snaží rozdělit n pozorování do k skupin kde ($k \leq n$) a $S = \{ S_1, S_2, S_3, \dots, S_k \}$ s cílem minimalizovat funkci:

$$\arg \min \sum_{i=1}^k \sum_{x_j \in S_i} \|s_j - \mu_i\|^2, \quad (3.35)$$

kde μ_i je střední hodnota bodu v S_i .

Obecně se metody prahování a shluková analýzy nehodí na přímou segmentaci obrazu, protože obraz je komplexní struktura, obsahující kromě informace popředí a pozadí ještě šum a různé další informace související s objektem jako je např. stín. Při přímé segmentaci také často dochází s tvorbě nespojitostí, jak jednotlivých částí obrazu, tak i ploch obrazu, kterým se označují jako díry. Tyto nespojitosti se dají určitým způsobem kompenzovat, ať už jednoduššími metodami jakými jsou **morfologické operace**, nebo sofistikovanějšími metodami jako **Markovská náhodná pole (MRF)** [54][55]. Při použití statistické metody využívající MRF se vychází z předpokladu, že výskyt nespojitosti oblastí, které se projevují dírami a výskyt malých osamocených objektů je v oblasti reálných objektů, které jsou v obraze reprezentovány jasem či barvou, statisticky velice nepravděpodobným jevem a dále také využívá toho, že je velice pravděpodobné, že sousední body patří do stejné skupiny. Bohužel je velice složité určit parametry vymezující vztah mezi jednotlivými body a tím správně automaticky řídit proces segmentace.

Popsané statistické metody lze využít také pro **prahování transformovaných obrazů**. Nejčastěji se můžeme setkat s prahováním obrazů, které jsou transformovány pomocí **hranových detektorů**. Základní použití spočívá v konvoluci masky reprezentující hranový detektor s obrazem. Podle principu můžeme hranové detektory rozdělit do třech skupin. První skupinou jsou hranové detektory založené na hledání maxim prvních derivací obrazové funkce. Druhá skupina je založena na hledání průchodu nulovou úrovní druhých derivací obrazové funkce a třetí skupina nevyhází z derivací obrazové funkce, ale je založena na aproximaci obrazové funkce polynomem. Mnohem častěji používané jsou však první dvě skupiny, kam patří Sobelův, Robertův, Prewittové, Cannyho a Marr-Hildreth detektor (druhá derivace) [28]. Výhodou detektorů první derivace obrazové funkce spočívá jednak v tom, že se daná funkce nemusí normalizovat, protože nevznikají záporné jasové složky obrazu, jak je tomu u druhé derivace obrazové funkce a pak také v směrovosti těchto operátorů. Můžeme díky tomu získat informaci o směru hrany detekované v obraze což se využívá v některých sofistikovaných detekčních algoritmech například u algoritmu **Histogram of Oriented Gradient**, který se používá pro detekci lidí ve statickém obraze. Příklady vertikální S_V a horizontální S_H konvoluční masky Sobelova hranového detektoru pro hledání maxim první derivace obrazové funkce mají tvar:

$$S_V = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix}, \quad S_H = \begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix}. \quad (3.36)$$

Aplikací masek na obraz získáme dva obrazy, kdy jeden obsahuje nalezené vertikální hrany a druhý obsahuje nalezené horizontální hrany. Z těchto obrazů lze následně dopočítat jednak modul, který nám poskytuje informaci o velikosti hrany a dále fázi, která nám poskytuje informaci o směru gradientu v daném bodě obrazu. Modul a fáze je definována podle vztahů:

$$M = \sqrt{(S_V^2 + S_H^2)}, \quad \Phi = \arctg\left(\frac{S_V}{S_H}\right). \quad (3.37)$$

Některé algoritmy vycházejí z předpokladu, že známe určité informace o objektu jakým je nejčastěji tvar. Jako jeden ze základních algoritmů, kde se využívá znalosti tvaru v kombinaci s obrazem získaných hranovou detekcí, je považována **Houghova transformace obrazu** [28][29]. Jde o transformaci hranového obrazu do Houghova prostoru, jehož počet dimenzí odpovídá počtu proměnných analytického popisu hledaných tvarů v obraze. Původně tato metoda byla navržena pro hledání přímek v obraze, které jsou definovány rovnicí:

$$r = x \cos \Phi + y \sin \Phi, \quad (3.38)$$

kde r označuje vzdálenost přímky od počátku, x a y značí vzdálenost v osách x a y od počátku souřadnic a Φ určuje úhel, který svírá normála popsané přímky s osou x . Houghova transformace se snaží na základě parametrů z rovnice (3.38) vykreslit přímku v Houghově prostoru, který je pro případ přímky trojrozměrný. První rozměr je určen úhlem Φ , druhý rozměr je vzdálenost od počátku reprezentovaná parametrem r a třetí rozměr nám udává pravděpodobnost výskytu přímky s parametry r a Φ a je nejčastěji reprezentován intenzitou jasu. Pro třetí rozměr se iteračně (obvykle o hodnotu 1) zvyšuje pravděpodobnost s každým nalezeným bodem v hranovém obraze. Tento rozměr se pohybuje v rozmezí 0 do π . V takto iteračně spočítaném Houghově prostoru se následně stanoví vhodný práh, pomocí kterého se určí maxima intenzit pro vektory r a Φ . Nalezené vektory reprezentují přímky dané rovnicí:

$$y = \left(-\frac{\cos \phi}{\sin \phi}\right)x + \left(\frac{r}{\sin \phi}\right). \quad (3.39)$$

Na podobném principu lze založit i segmentaci jiných geometrických útvarů jakými jsou kružnice, elipsy atd. Houghova transformaci lze však využít i pro hledání obecného tvaru objektu. Využívá se k tomu **zobecněná Houghova transformace**. Postup je velice podobný jako u základních geometrických útvarů jakými je např. popsaná přímka. U obecné Houghovy transformace se vychází z exaktního popisu objektu. Každý bod hledané křivky může být definován jako bod vztažený k předem zvolenému bodu, kterým je nejčastěji těžištěm daného objektu. Definujeme-li si těžiště jako bod o souřadnicích x_c , y_c , potom pro každý bod na hranici objektu je definován parametry:

$$r = \sqrt{(x - x_c)^2 + (y - y_c)^2}, \quad \beta = \tan^{-1}(y - y_c)/(x - x_c), \quad (3.40)$$

kde r odpovídá vzdálenosti bodu na hranici objektu od těžiště a β určuje úhel mezi spojnicí těžiště a hraničního bodu s osou x . Pro toto zadání má hledaný objekt stejný tvar, stejnou velikost a má stejnou orientaci. Pro případ změny měřítka a různé orientace je zapotřebí zavést ještě parametry S změny měřítka a γ úhlu rotace. Dostáváme se však již do pětirozměrného Houghova prostoru, což má velký vliv na časovou náročnost algoritmu.

Pro segmentace, kdy známe tvar objektu se využívá v poslední době velice rozšířená metoda **AAM** [56]. Princip této metody spočívá v získání statistických informací o tvaru z ručně segmentované dostatečně velké sady objektů, ze kterých je za pomoci metody PCA[57] vytvořen model. Na základě získaného modelu lze objekt v obraze detekovat a určit jeho polohu. Tato technika je velice časově náročná při tvorbě modelu, kdy je nutné ručně vytvořit velký počet přesných předloh, ze kterých se zjišťují vlastnosti. Tento algoritmus však při aplikaci na obraz již dokáže pracovat velice rychle (i v reálném čase) a efektivně. Velice problematické je však vytvořit kvalitní model. Obecně je použití metod pro segmentaci obrazu na základě tvaru objektu u biomedicínkových obrazů velice problematické, protože ve většině případů se snažíme detekovat nějakým způsobem poškozenou tkáň, která s velkou pravděpodobností nebude vykazovat tvarovou stabilitu a mnohdy může dojít i k destruktivním deformacím tkáně, které nemusí mít žádnou podobnost s původním tvarem. Příkladem může být naprostá deformace kloubního disku, který je nejdůležitější částí TMK, který se snažíme segmentovat.

Další skupinou segmentačních algoritmů jsou regionově orientované segmentace, do které patří metody **segmentace růstem oblastí**, **segmentace dělením a slučováním oblastí** a metoda **rozvodí**. První zmiňovaná metoda vychází z podobné myšlenky jako již popisovaná metoda shlukové analýzy. Zde se však vychází z rozdělení obrazu na části, často až do velikosti pixelu a následně se definují kritéria pro slučování jednotlivých oblastí do větších celků podle předem daných pravidel jejich homogenity. Kritéria pro slučování mohou záviset na různých vlastnostech obrazu, jakými mohou být jasové vlastnosti, barva, nebo třeba vlastnosti textury jednotlivých oblastí. Mezi jedny z nejpoužívanějších kritérií patří síla společné hranice vycházející z jasových vlastností pixelů s_i a s_j mezi sousedními oblastmi.

$$v_{i,j} = \begin{cases} 1 & \text{pro } |s_i - s_j| < T_a \\ 0 & \text{ostatní} \end{cases}, \quad (3.41)$$

kde T_a je práh určující sílu hrany v daném bodě. Abychom stanovili sílu celé hrany, testuje se délka společné hranice v závislosti na síle hrany

$$\frac{W}{\min(l_i, l_j)} < T_b, \quad (3.42)$$

kde W je počet slabých hran po celé délce hranice. Samozřejmě záleží na zvoleném způsobu výpočtu kritérií, ale jak je vidět na předešlém výpočtu i u toho nejjednoduššího principu není snadné stanovit počáteční parametry. Lepší výsledky vykazuje metoda segmentace dělením a slučováním oblastí, která vychází z předchozí metody a zaměřuje se na prvotní rozdělení obrazu na malé části. Toto rozdělení ve tvaru stromu, kdy se obraz rozděluje postupně od větších do menších oblastí, přičemž jsou jednotlivé oblasti při každém rozdělování testovány a dělí se pouze ty, které splní stanovenou podmínku. Ve chvíli, kdy dojde ke konvergenci při rozdělování, postupuje se opačně a testují se sousední regiony na kritéria pro sloučení, podobně jak je tomu u předchozí metody. Výsledkem je rozdělený obraz do bloků kdy

informace o jednotlivých blocích nalezneme v jednotlivých uzlech stromu. Posledním algoritmem, se kterým se ve zpracování biomedicínckých obrazů můžeme docela často setkat algoritmus rozvodí. Algoritmus vychází z představy, že obraz je trojrozměrný a lze ho připodobnit terénu, který může obsahovat údolí, hory atd. Tmavé oblasti obrazu nám vytvářejí lokální minima, která zde reprezentují údolí. V oblastech těchto minim se obrazně vlévá do obrazu voda, která postupně zaplavuje celý obraz. V místech kde se slévá voda ze dvou zdrojů, se vystavějí virtuální hráze, které reprezentují hranice mezi jednotlivými objekty. Segmentace končí ve chvíli, kdy jsou všechny části zaplaveny a to i maxima obrazu. Výsledkem segmentace je obraz s velkým množstvím segmentovaných objektů a podobně jako je tomu u předchozích dvou popsaných metod jednotlivé sousedící objekty se testují na homogenitu na principu jasové funkce, barvy, nebo textury. Pokud jsou splněny podmínky homogenity sousedící objekty se sloučí. Nepříjemnou vlastností, která vyplývá z vlastního principu algoritmu je vysoká citlivost na šum. Nejčastěji se totiž šum projevuje lokálními maximy, nebo minimy, které ovlivňují jednak počáteční podmínky algoritmu, a dále ovlivňují oblasti, kde dochází tvorbě hranic. Vliv šumu na algoritmus rozvodí se projevuje přesegmentováním obrazu, kdy je obraz složen z velkého množství lokálních objektů. Tento nedostatek se do jisté míry dá řešit pomocí předzpracování obrazu, kdy se alespoň z větší části z obrazu odstraní šum.

Zvláštní skupinou segmentačních metod jsou algoritmy využívající fuzzy přístupy a neuronové sítě. Jedním z reprezentantů skupiny s fuzzy přístupem je metoda zvaná **fuzzy propojenost** [58]. Princip této metody spočívá v jednak sledování homogenity oblastí, jako je tomu u předchozích metod, ale pro upřesnění se využívá i sledování strukturních informací objektu. Vlastní segmentace probíhá na základě výpočtu podobnosti objektů váhovaním sumy intenzit a obrazových derivací v okolí bodů. Nevýhoda této metody je v tom, že neumožňuje využití znalostí tvaru segmentovaných objektů a dále co je větší nevýhodou, že vlastní segmentace je závislá na stanovených fuzzy pravidel a vlastnostech obrazových oblastí. Segmentační metody založené na **neuronových sítích** [59] se prosazují nejčastěji v oblastech, kde hledáme objekty podobných vlastností a to hlavně těch tvarových. Neuronová síť nám slouží spíše jako klasifikátor pro rozhodování při rozdělování oblastí. Jako vstup do neuronové sítě je nejčastěji vektor příznaků, který nám popisuje danou oblast a neuronová síť rozhoduje, zda je daná oblast segmentovaný objekt či nikoliv. Apriorně nelze použít neuronovou síť tak, že by vstupem byly jednotlivé pixely a ona byla na základě vnitřní logiky schopna rozdělit předložený prostor na objekty, i když se tento přístup nabízí. Je totiž nutné omezit množství informace a přepracovat ji do formy, která je neuronovou sítí lépe reprezentovatelná. Nevýhodou neuronových sítí je nutnost mít soubor ručně segmentovaných vstupních dat, které slouží pro vlastní naučení neuronové sítě, přičemž právě vlastní proces učení je velice složitý a zdlouhavý. Právě náročnost procesu učení neuronových sítí je hlavní příčinou toho, že se tyto algoritmy příliš nerozšířily.

Všechny předchozí metody nějakým způsobem vždy měnily vlastnosti obrazu tak aby vznikly hranice mezi jednotlivými objekty. Poslední dobou se však využívá jiného přístupu, kde se na základě vlastností obrazové funkce modifikuje tvar jiné funkce, která reprezentuje hranici objektu. Tyto algoritmy se nazývají **aktivní kontury** [60][61][62]. Tyto algoritmy jsou vždy iterační s počátečními podmínkami, které na základě vlastností obrazu tvarují uzavřenou křivku reprezentující hranici objektu. V principu se jedná o minimalizaci energetické funkce dané vztahem:

$$\int_0^1 E_{\text{snake}}(v(s))ds = \int_0^1 [E_{\text{internal}}(v(s)) + E_{\text{image}}(v(s)) + E_{\text{constrain}}(v(s))]ds, \quad (3.43)$$

kde $v(s)$ reprezentuje parametrickou křivku, s je délka kontury. E_{internal} , E_{image} a $E_{\text{constrain}}$ reprezentují jednotlivé energetické funkce, ze kterých je složena celková energetická funkce E_{snake} . Jednotlivé Energie lze definovat s pomocí váhových funkcí. Energetická funkce E_{internal} reprezentuje vnitřní energii kontury, která lze definovat

$$E_{\text{internal}} = \alpha(t) \frac{\partial v(t)}{\partial t} + \beta(t) \frac{\partial^2 v(t)}{\partial^2 t}, \quad (3.44)$$

Váhová funkce $\alpha(t)$ definuje hladkost kontury a váhová funkce $\beta(t)$ definuje pružnost kontury. Hlavní vliv těchto váhových funkcí je znatelný v ostrých zlomech kontury, kde lze přizpůsobovat tvar kontury hranám obrazu a regulovat její zaoblenost. Oproti vnitřním silám daným energetickou funkcí E_{internal} jsou vnější síly dané energetickou funkcí E_{image} složeny z dalších energetických funkcí, které ovlivňují křivku na základě vlastností obrazu. Matematicky lze energetickou funkci E_{image} rozdělit podle následujícího vzorce:

$$E_{\text{image}} = w_{\text{line}} E_{\text{line}} + w_{\text{edge}} E_{\text{edge}} + w_{\text{term}} E_{\text{term}}, \quad (3.45)$$

kde E_{line} určuje závislost kontury ke světlým, nebo tmavým částem obrazu, reprezentujícím lokální maxima či minima. Velikost váhy je dána váhovým faktorem w_{line} . Matematicky lze E_{line} definovat jako funkci parametrické kontury $v(t)$:

$$E_{\text{line}} = f(v(t)) \quad (3.46)$$

Následující energetickou funkcí ve vzorci (3.45), která ovlivňuje vnější síly je E_{edge} . Tato energetická funkce lze definovat pomocí vzorce:

$$E_{\text{edge}} = -|\nabla f(v(t))|^2 \quad (3.47)$$

a tvaruje kontury na základě analýzy míst s vysokou hodnotou velikosti gradientu obrazu. Tato funkce závisí na použité gradientní funkci pro detekci hran v obraze. Protože se v těchto oblastech může nacházet šum, který ovlivňuje velikost gradientu v daném bodě je výhodné před vlastní detekcí hran obraz filtrovat pomocí filtru typu dolní propusti, jakým je například Gaussovské rozostření, aby došlo k filtraci šumu obsaženého ve vyšších frekvenčních složkách. Poslední energetická složka vnějších sil je energetická funkce E_{term} , která na základě analýzy křivosti kontury detekuje ostré hrany. Pokud se pohybuje v oblasti rovné, nebo hladké hrany je její hodnota malá. Podobně jako u E_{edge} i zde nám šum může ovlivnit vlastnosti detekce ostrých hran, a proto se i zde využívá filtru, který obraz rozmaže.

Poslední energetickou funkcí ve vzorci (3.45) je $E_{\text{constrain}}$, který reprezentuje externí síly ovlivňující tvar kontury řízené uživatelem, který tak může ovlivňovat chování kontury během jednotlivých cyklů a zavádí do detekce nezávislé podmínky. Parametrické vyjádření kontury, které lze definovat jako množinu bodů danou rovnicí

$$C(t) = \{(x(s, t), y(s, t)) | 0 \leq s \leq 1\}, \quad (3.48)$$

nám zanáší do výpočtu mnoho matematických složitostí a z toho vyplývajících nevýhod této metody. Jako jednu z největších nevýhod lze považovat neúměrné zvýšení složitosti výpočtu při rozšíření do vícedimenzionálního prostoru. Pro vícerozměrnou soustavu je velice obtížné definovat parametricky počáteční objekt a přepočítání tvaru a pohybu během jednotlivých iterací. Nárůst složitosti implementace je neúměrně vysoká a pro složitost stanovení jednotlivých energií nedává ani přijatelné výsledky. Problémy nastanou i při rozdělování či slučování hranice kontury během jednotlivých iterací. Během segmentace se mohou jednotlivé oddělené hranice spojovat, rozdělovat, nebo dokonce zanikat. Pro tyto případy je nutné stanovit složité postupy, které tyto operace budou matematicky řešit. Další nevýhoda souvisí se změnou tvaru kontury. Vyjdeme-li z předpokladu, že kontura je dána sadou rovnoměrně rozložených bodů hranice, potom musí platit vztahy mezi konturou $C(t)$ a $C(t+\Delta t)$. Při přepočítání kontury $C(t)$ pomocí aproximace parciální derivace na $C(t+\Delta t)$ může dojít k tomu, že vlivem složitějšího tvaru kontury dojde k nerovnoměrnému rozdělení bodů na hranicích kontury. Některé body se k sobě mohou neúměrně přibližovat a jiné zase oddalovat. Je tedy nutné při každé iteraci provést přepočítání postavení všech bodů na hranici kontury, tak aby znovu měli rovnoměrné rozložení. Tento postup je označován jako reparametrizace kontury. Kdyby se reparametrizace při každé iteraci neprovedla, mohlo by to vést až k numerickému selhání metody a to už po několika iteracích. Pro výše zmíněné nevýhody bylo přistoupeno k popisu kontury za pomoci tzv. úrovněvé množiny – LSM [61][62]. Množina LSM využívá k popisu kontury průnik roviny s úrovněvou funkcí. Tvar této funkce je dán počátečními podmínkami a řešením parciálních diferenciálních rovnic nad touto funkcí. Nevýhodou této reprezentace je, že při každé iteraci se počítá parciální diferenciální rovnice nad velkým objemem čísel, které jsou dány velikostí obrazu. Objem čísel se dá snížit přepočítáváním jen oblasti v nejbližším okolí křivky, což je pod názvem rychlá LSM popsáno v [63].

LSM vychází ze základní rovnice [61]:

$$\frac{\partial \phi}{\partial t} + F|\nabla \phi| = 0, \quad (3.49)$$

kde $\phi(t, x, y)$ je LS funkce, která se vyvíjí podle rychlostní funkce F v čase t . Kontura je pak definována řezem v nulové hladině vícerozměrné funkce LS a lze ji definovat vztahem:

$$C(t) = \{(x, y) | \phi(t, x, y) = 0\} \quad (3.50)$$

Počáteční a hraniční podmínky, které stanovují počáteční funkci a podmínky detekce jsou dány vztahy:

$$\frac{d\phi}{dt} = 0 \text{ na hranicích oblasti } \Omega, \quad (3.51)$$

$$\phi(0, x, y) = \bar{d}(x, y, c_0) = \begin{cases} +d(x, y, c_0) & \text{pokud } x \text{ je vně } c_0 \\ -d(x, y, c_0) & \text{pokud } x \text{ je uvnitř } c_0 \end{cases}, \quad (3.52)$$


kde $d(x, y, c_0)$ značí euklidovskou vzdálenost od počáteční kontury c_0 .

LSM lze využít i k detekci na základě tvaru, textury či střední hodnotě jasu. Je tedy závislá na matematickém popisu podmínek analýzy objektu. Obecně se jedná o velice robustní metodu, která se v poslední době často využívá k segmentaci složitých tvarů, které vykazují výrazné statistické vlastnosti.

3.4 Tvorba 3D modelu


Další v pořadí řetězce tvorby 3D objektu (viz obr. 3.1) je modul převodu 2D segmentovaných řezů, které reprezentují jednotlivé voxely tkáně do vektorového tvaru polygonálního modelu. Polygonální geometrie vychází z tvorby povrchu modelu za pomoci sítě polygonů, které jsou tvořeny přímkami propojených vrcholů. Vzniká tak síť po částech lineárních, hraničně omezených polorovin, které na sebe navazují.

V oblasti převodu voxelů na polygonální model se nejvýrazněji prosadila technika zvaná **Marching Cubes** (Pohybující se kostka). Původní návrh se datuje do roku 1987 kdy ji v [64] publikovali W. E. Lorensen a H. E. Cline. Pro polygonální vyjádření povrchu modelu se zde využívá trojúhelníků a je vždy aplikován na dva po sobě jdoucí řezy tkání. Tato technika využívá obecného principu rozděl a panuj pro nalezení logické krychle. Posouváním této krychle v oblasti mezi sousedními vrstvy se vytváří logická prostorová mřížka. Po průchodu krychlí celým prostorem se protnutím hran krychle vytvoří povrch tvořený trojúhelníky. Při vytváření hraničních pozic se vychází z obecného principu, že krychle má osm vrcholů, a každý z těchto vrcholů se může nalézat uvnitř, nebo vně vytvářeného tělesa v závislosti na parametrech segmentovaných obrazů sousedních řezů. Umístění vrcholů lze rozdělit na dva stavy. První stav nastává, pokud je vrchol umístěn uvnitř, nebo na povrchu tělesa a druhý stav nastává, pokud je umístěn vně tělesa. Z tohoto předpokladu lze odvodit, že celá kostka se může nacházet v jednom z $2^8 = 256$ možných rozpoložení. Z čehož vyplývá, že rozložení krychle v závislosti na umístění jednotlivých vrcholů vně nebo uvnitř tělesa lze zobecnit na 256 možných stavů. V praxi se stavy realizují, jako binární číslo, kde jednotlivé pozice určují vrcholy krychle, jak je patrné z obr. 3.7.. Jak je z obrazu patrné jednotlivá binární čísla nám určují, který vrchol je uvnitř, a který je vně objektu. Stav daný binárním číslem nám následně jednoznačně určí, které hrany vyobrazené na obr. 3.7 b) budou protnuty povrchem a v jakém pořadí bude probíhat triangulace vrcholů.



Obr. 3.7: Ukázka indexování a) vrcholů krychle b) hran krychle

Když bychom vzali v úvahu podobnost některých stavů, které jsou při otočení, či zrcadlení totožné, lze omezit stavy krychle pouze na hodnotu 15 základních stavů, ze kterých lze zbývající stavy dopočítat. Těchto 15 základních stavů krychle je možné graficky znázornit jak je vidět na obr. 3.8.



Obr. 3.8: Základní stavy krychle metody Marching Cubes

V obr. 3.8 můžeme vidět minimální počet stavů krychle metody Marching Cubes. S těmito stavy souvisejí i chyby, které metoda Marching Cubes vykazuje. Jedná se o nejednoznačnosti jednotlivých stavů, a s tím související problém vzniku děr v isoplochách. Dochází k tomu za situace, kdy se nacházejí dva nejednoznačné stavy vedle sebe. Z těchto důvodů vznikly další algoritmy, které jsou odvozením metody Marching Cubes a řeší problémy s nejednoznačností. Mezi tyto metody patří **Chernyaevova Marching Cubes 33**, která je tvořena větším množstvím stavů základní kostky, které už neobsahují nejednoznačnost výkladu, avšak je zde složitější mechanismus správného určení stavu. Další metoda, která řeší nejednoznačnosti je **Marching Cubes s garantovanou topologií** popsaná v [65]. Tento algoritmus provádí vytvoření polygonálního modelu stejně jako je tomu u původní metody s tím rozdílem, že pokud kontrolou topologie nalezne nesourodost, tak se vybere jiný možný výklad rozložení polygonální mřížky a znovu se otestuje topologie. Výsledkem je výběr nejpravděpodobnější rozložení mřížky. **Marching tetrahedrons** je metoda, která využívá jako základní stavební kámen tetrahedron namísto krychle. Využití tetrahedronu namísto krychle se vyvarujeme nejednoznačností, avšak je to vykompenzováno určitými nevýhodami. V první řadě se jedná o náročnější výpočty během určování hraničních rozpoložení tetrahedronu a s tím související časová náročnost algoritmu, přestože základní tabulka stavů je mnohem nižší, než je tomu u Chernyaevovy Marching Cubes 33 metody. Další a mnohem významnější nevýhodou je problematické vykreslování členitých oblastí modelu, kde na rozdíl od tetrahedronu lze kostku lépe přizpůsobit geometrickým rozložením objektu. S tím souvisí i větší počet trojúhelníků výsledného polygonálního modelu.

Závěrečná fáze procesu tvorby modelu se zabývá zpracováním a úpravou již trojrozměrného modelu tvořeného polygonální sítí. Tento závěrečný modul zahrnuje několik typů operací, které se s trojrozměrným modelem provádějí. V první řadě se jedná o **decimaci**. Při decimaci se prochází polygonální model a slučují se jednotlivé buňky do větších struktur na základě jejich směrových vektorů.

4 Cíle dizertace

Cílem dizertační práce je návrh metod pro tvorbu 3D modelu kloubní hlavice a kloubního disku u temporomandibulárního kloubu. Velice důležitou částí tvorby realistického modelu je vytvoření segmentačních metod, které by dokázaly účinně segmentovat kloubní hlavici a kloubní disk z 2D řezů vytvořených pomocí tomografu magnetické rezonance. V této oblasti je velice důležité správně segmentovat kloubní disk, který vykazuje velmi slabý kontrast v porovnání s jeho nejbližším okolím, což je problematické pro použití běžných segmentačních metod.

Dizertační práce řeší následující problémy:

- návrh filtrů pro odstranění šumu ze vstupních dat,
- návrh segmentačních metod, které by dokázaly segmentovat měkkou tkáň kloubního disku, jež má velmi nízký kontrast a splývá s okolní tkání. Pro segmentaci bude využita informace založená na znalosti anatomie pohybu kloubního disku a pozice kloubní hlavice,
- návrh metody pro objektivní kvalitativní zhodnocení segmentačních metod pro 3D data magnetické rezonance,
- dopočítání dat v ose z, tak aby co nejvíce odpovídaly tvarovým vlastnostem segmentované tkáně a to jak pro kloubní hlavici, tak i pro kloubní disk,
- rekonstrukci 3D modelu temporomandibulárního kloubu,
- návrh metody pro objektivní kvalitativní vyhodnocení míry zkreslení rekonstruovaného modelu, při decimaci a vyhlazování polygonální sítě.

5 Teoretická analýza nově navržených metod

5.1 Segmentace kloubní hlavice z MRI snímků

Při vývoji nové metody pro segmentaci kloubního disku z MR snímků je velice důležité nejprve detekovat kloubní hlavici. Jak je uvedeno v kapitole 2, kloubní disk se vždy objevuje v prostoru, který je vymezen právě kloubní hlavici. Při návrhu nové metody, která provádí segmentaci kloubního disku, bylo využito znalosti anatomického uložení kloubu, kdy bylo zjišťováno pravděpodobnostní uložení kloubního disku na základě možné pozice kloubní hlavice. Protože oproti kloubnímu disku, má kloubní hlavice ve snímcích větší kontrast, bylo pro segmentaci kloubní hlavice využito metody značkami řízeného rozvodí. [28]



Obr. 5.1: Příklad MRI obrazu pro segmentaci kloubní hlavice

Metoda značkami řízeného rozvodí (watershed method) si představuje obraz jako reliéf, kde tmavé oblasti jsou považovány za nížiny a světlé oblasti za hřebeny. Tato metoda se skládá z několika kroků:

- Výpočet segmentační funkce. Jedná se o obraz kde tmavé regiony značí objekty, které se pokoušíme segmentovat.
- Výpočet značek popředí. Jedná se o obraz tvořený shlukem pixelů, které jsou vždy uvnitř každého objektu.
- Výpočet značek pozadí. Jedná se o obraz s pixely označujícími oblasti, které nejsou považovány za objekty.
- Modifikace segmentační funkce tak, že obsahuje minima pouze na místech značek symbolizujících popředí a pozadí.
- Výpočet metody rozvodí pro modifikovanou segmentační funkci.

Pro segmentaci obrazu pomocí rozvodí je často využíváno gradientního operátoru. Při aplikaci gradientního operátoru na obraz jsou nalezeny hranice objektů, které vykazují nejvyšší strmou. Gradientní funkce f v bodě (x, y) je definována jako sloupcový vektor:

$$\nabla f = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (5.1)$$

Velikost samotného vektoru se označuje jako *gradient*. Prvky gradientního vektoru jsou lineární, zatímco *gradient* vlivem operací mocnění a odmocnění není lineární. Výsledná velikost gradientního vektoru vykazuje invarianci k rotaci. *Gradient* lze zjednodušit do tvaru podle této rovnice

$$\nabla f = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2} = \sqrt{G_x^2 + G_y^2} \approx |G_x| + |G_y| \quad (5.2)$$

V našem případě to také může způsobit přesegmentování, čímž dojde k rozdělení obrazu na velké množství malých regionů, které nevyznačují významné objekty jako celky, ale rozdělují je jen na malé části. Je velice obtížné následně seskládat významné objekty z těchto malých regionů. Tato vlastnost je pro základní metodu rozvodů velice typická. Proto byla navržena rozšířená verze této metody, a to značkami řízené rozvodí. Takto upravená metoda uvádí jen obecný předpis, jaké vlastnosti by měly jednotlivé značky mít. Mnohem složitější je však navrhnout způsob, jak oblasti automaticky nalézt, a to se řeší na základě specifických vlastností obrazu.[28]

V případě segmentace kloubní hlavice se osvědčilo využití morfologických operací. Základní morfologické operace jsou definovány pro binární obraz a pracují se dvěma a více množinami, kde první množina je tvořena vstupním obrazem A , a další jsou označeny za strukturální elementy. U základních operací, jakými jsou eroze, dilatace, otevření a uzavření, je potřeba jen jedna další množina, tedy pouze jeden dvourozměrný strukturální element B . U vyšších morfologických operací, jakými je například hit-and-miss transformace se pracuje s více množinami. Jednotlivé elementy v množině jsou reprezentovány jako uspořádaný pár v dvojdimenzionálním euklidovském prostoru E^2 . Při definici dilatace u binárního obrazu se provádí kombinace strukturálního elementu s obrazem za pomoci Minkovského součtu, což se dá matematicky popsat pomocí vztahu [67]

$$A \oplus B = \{c \in E^2: c = a + b, a \in A \wedge b \in B\} \quad (5.3)$$

Duální operací k dilataci je eroze, kterou lze na binárním obraze definovat vztahem:

$$A \ominus B = \{c \in E^2: c + b \in X \text{ pro všechny } b \in B\} \quad (5.4)$$

Pro morfologické operace v šedotónovém obraze jsou jednotlivé obrazy funkce, které mapují Euklidovský prostor E do $\mathfrak{R} \cup \{\infty, -\infty\}$. Pokud obraz označíme jako funkci $f(x)$ a strukturální funkci jako $b(x)$, potom operace dilatace v obraze $f(x)$ pomocí strukturální funkce $b(x)$ je dána vztahem

$$(f \oplus b)(x) = \sup_{y \in E} [f(y) + b(x - y)], \quad (5.5)$$

kde *sup* značí supremum.

Eroze v šedotónovém obraze, která pomocí strukturní funkce b provádí morfologické operace na obraze f , je definována vztahem

$$(f \ominus b)(x) = \inf_{y \in E} [f(y) - b(y - x)], \quad (5.6)$$

kde \inf značí infimum. Při kombinaci dilatace a eroze vznikají další operace, kterými jsou otevření a uzavření. Otevření lze definovat vztahem takto

$$f \circ b = (f \ominus b) \oplus b \quad (5.7)$$

a uzavření lze definovat tímto vztahem

$$f \bullet b = (f \oplus b) \ominus b \quad (5.8)$$

Všechny definované morfologické operace jsou monotónní funkce, které jsou invariantní proti posunutí. Využití základních morfologických operací je velice omezené a to i přes možnost různé definice strukturní funkce. V šedotónovém obraze lze definovat pokročilejší funkce, které se používají pro vyhlazení uzavřené oblasti, tak aby vykazoval homogenní charakter. V pramenu [68] je popsána funkce nazývaná jako morfologická rekonstrukce. Existují dva ekvivalentní přístupy jak tuto funkci definovat [68]. Pokud vyjdeme z principu superpozice, potom morfologická rekonstrukce šedotónového $\rho_I(J)$ obrazu I pomocí šedotónového obrazu J za podmínky:

$$J(p) \geq I(p) \quad \text{pro každý pixel } p \in D_I \quad (5.9)$$

kde D_I značí diskretní prostor konečných čísel platný pro J i I (Pro 8bit šedotónový diskretní obraz je D_I v intervalu $\langle 0;255 \rangle$) je dána vztahem:

$$\forall p \in D_I, \quad \rho_I(J)(p) = \max\{k \in [0, N-1] \mid p \in \rho_{T_k(I)}(T_k(J))\}. \quad (5.10)$$

U morfologické rekonstrukce je důležitým parametrem funkce J . Tato funkce může mít vztah s původním obrazem. Výpočtem funkce J jako dilatace obrazu I vznikne funkce, která se nazývá *otevření pomocí rekonstrukce* a dá se vyjádřit matematicky vztahem:

$$\rho_I(J) = \rho_I(I \oplus B) \quad (5.11)$$

Duální operací je operace *uzavření podle rekonstrukce*, které lze vyjádřit pomocí vztahu:

$$\rho_1(J) = \rho_1(I \ominus B) \quad (5.12)$$

Vydeme-li z předchozích operací a dvourozměrný řez MRI označíme jako I , potom inicializační funkce popředí F je výsledkem následujících operací. Nejprve se algoritmus zaměřuje na vyhlazení regionů, tak aby nám vznikla regionální maxima. Takto filtrovaný obraz I_1 je dán vztahem:

$$I_1 = N - (\rho_{I_0}((N - I_0) \ominus B)) \quad (5.13)$$

kde I_0 je $\rho_1(I \oplus B)$, tedy *otevření podle rekonstrukce* obrazu I . Výsledkem tohoto filtru je vyhlazení regionů, které spolu sousedí a mají podobné jasové vlastnosti. Můžeme tedy mluvit o homogenizaci regionů v šedotónovém obraze. Jak již bylo zmíněno, filtr vytváří regionální maxima reprezentující objekty. Vytvoření lokálních maxim je dobře znatelné na obr. 5.2.



Obr. 5.2: Zpracování obrazu pomocí filtru využívajícího morfologické operace

Vyjádríme-li si regionální maximum šedotónového obrazu I jako množinu pixelů M s hodnotou h , potom je regionální maximum definováno jako soubor navazujících pixelů, kde všechny okolní sousední pixely mají hodnotu nižší, než je hodnota h . Pokud to vztáhneme k obrazu I , potom je regionální maximum o výšce h v šedotónovém obraze I spojitou oblastí C , která musí splňovat podmínku:

$$C \cap T_{h+1}(I) = 0 \quad (5.14)$$

kde $T_h(I)$ reprezentuje prahování obrazu I . Pro detekci regionálních maxim v obraze existuje velké množství algoritmů, jak je popsáno v pramenu [69]. Jedna z nejčastěji používaných

metod využívá popsané morfologické rekonstrukce. Definujeme si $M(I)$ jako funkci obrazu I , která nám udává binární obraz s vyznačenými regionálními maximy. Tato funkce je pak dána vztahem:

$$M(I) = I - \rho_I(I - 1) \quad (5.15)$$

Předchozí vztah předpokládá regionální maxima ve stejné úrovni h , což je limitní případ, který v obecné segmentaci nastává jen velmi zřídka, a proto je nutné vztah zobecnit. Pokud vyjdeme z definice podmínek (5.14) pro regionální maximum v obraze I , pak jeho rozšířením získáme vztah:

$$C \cap T_{h+1}(I) = C \cap T_h(I - 1) = 0 \quad (5.16)$$

Po aplikování této podmínky do algoritmu pro detekci regionálních maxim dostaneme vztah:

$$M_h = T_h(I) \setminus \rho_{T_h(I)}(T_h(I - 1)) \quad (5.17)$$

Výsledkem je soubor binárních obrazů, kde pro jednotlivé hladiny h jsou vykresleny regionální maxima. Tyto maxima sice reflektují homogenní oblasti jednotlivých objektů, ale nedokáží dostatečně obsáhnout oblasti, které jsou v hraničních částech těchto objektů a nevykazují homogenní charakter v plném rozsahu. Protože však potřebujeme mít všechny značky v jedné funkci, musíme sloučit jednotlivé detekce do jedné funkce M

$$M = \sum_{h=0}^N M_h \cup M_{h+1} \quad (5.18)$$

Nyní tedy máme dvourozměrnou binární funkci M , která obsahuje značky regionálních maxim. Definujeme-li si však objekt jako $O \in I$, potom základní podmínky, které značky popředí objektu musí splňovat, jsou $M_h \subseteq O$ a zároveň M_h musí být v celém rozsahu O spojitá plocha. Jak je vidět na obrázku obr. 5.3 druhou podmínku však výsledky M_h ze vztahu (5.17) nesplňují. V jednotlivých oblastech vzniká větší množství malých objektů, které mohou být špatně interpretovány jako další části pro zaplavování oblasti a tím může dojít k roztržení jednotlivých objektů na větší počet dílů.



Obr. 5.3: Regionální maxima ovlivněná lokálním šumem


Abychom předešli tomuto roztržštění, je nutné dodržet druhou podmínku. Toho se dosáhne pomocí operace uzavření v kombinaci s erozí. Matematicky lze tyto operace popsat vztahem:

$$M_{cr} = (M \bullet b) \ominus b = ((M \oplus b) \ominus b) \ominus b \quad (5.19)$$

Při operaci uzavření dojde k vyhlazení hraničních oblastí objektů popředí a následná eroze zmenší celkovou oblast a odstraní členitosti v hraničních oblastech M . Strukturní funkce b musí být volena s ohledem na velikosti děr v oblastech M_h . Při této operaci dojde k odstranění děr v objektech popředí a k částečnému odstranění nežádoucích objektů. I přes vhodně zvolenou strukturní funkci nemusí být odstraněny všechny drobné objekty, které vzniknou vlivem šumu a nehomogenity segmentovaných objektů. Vydeme-li však z předpokladu, že hlavní značky popředí jsou mnohonásobně větší, než je tento šum v jejich okolí, můžeme vytvořit funkci, která prochází celý binární obraz M_h a měří velikosti jednotlivých osamocených objektů. Pokud objekt nesplní podmínku, že je větší než zvolený práh P , potom je tento objekt z obrazu odstraněn. Práh P se volí jako procentuální zastoupení (např. 1%) velikosti největšího objektu. Protože je šum většinou reprezentován shlukem pouze několika pixelů, nemůže nikdy překročit tento práh. Matematicky to lze definovat následovně:

$$M_{cr}(s) = \begin{cases} 0 & \text{pokud } s > P \\ 1 & \text{pokud } s < P \end{cases} \quad (5.20)$$

kde s značí obsah značky popředí a P značí práh. Výsledný obraz M_{cr} nyní obsahuje pouze značky popředí v binární podobě. Pokud tyto značky vyznačíme do původního řezu MRI obrazu, dostaneme obr. 5.4, na kterém je vidět, že vytvořené značky jsou uvnitř jednotlivých částí objektů a mají hladké okraje bez nežádoucího šumu.



Obr. 5.4: Značky popředí zobrazené v MRI obraze hlavy

Na obr. 5.4 máme označeny body popředí, které nám určují, kam se bude „vlévat daná voda“ metody rozvodí. Nyní je nutné nalézt značky pozadí, které oddělí jednotlivé části objektů a vytvoří oddělující hranice, které se v odborné literatuře připodobňují přehradám v terénu, které zadržují vodu. Pro tvorbu hranic se vychází z výsledků I_I ze vzorce (5.13). Tento obraz obsahuje regionální maxima, které zvýrazňují plochy objektů. Pro pozadí je potřeba vytvořit úzké spojnice v oblastech mezi jednotlivými objekty. Regionální maxima jsou pro nás výhodné, protože zaplňují z velké části objekty a zmenšují prostor v oblastech mezi objekty. Vyjdeme-li z předpokladu, že potřebujeme rozdělit šedotónový obraz na dvě kategorie objektů, kde v první kategorii jsou regionální maxima a v druhé kategorii je pozadí, dostáváme se do oblasti prahování. Pro automatickou volbu prahu jsme zvolili algoritmus Otsu pojmenovaný podle jeho autora Nobuyuky Otsu [70]. Tento algoritmus vychází z hledání prahové hodnoty z histogramu obrazu na základě minimalizace rozptylu. Tento rozptyl je definován jako součet rozptylu dvou tříd:

$$\sigma_{\omega}^2(t) = \omega_1(t)\sigma_1^2(t) + \omega_2(t)\sigma_2^2(t) \quad (5.21)$$

kde ω_i jsou pravděpodobnosti jednotlivých tříd odděleny prahem t a σ^2 jsou rozptyly těchto tříd. Podle [70] lze odvodit, že minimalizace rozptylu uvnitř jednotlivých tříd odpovídá maximalizaci rozptylu mezi těmito třídami:

$$\sigma_b^2(t) = \sigma^2 - \sigma_{\omega}^2(t) = \omega_1(t)\omega_2(t)[\mu_1(t) - \mu_2(t)]^2 \quad (5.22)$$

kde μ_i značí střední hodnotu jednotlivých tříd. Pravděpodobnost třídy $\omega_1(t)$ se dá z histogramu vypočítat dle vztahu:

$$\omega_1(t) = \sum_0^t p(i) \quad (5.23)$$

a střední hodnota

$$\mu_1(t) = \frac{[\sum_0^t p(i)x(i)]}{\omega_1} \quad (5.24)$$

kde $x(i)$ je hodnota ve středu i -tého prvku histogramu. Výsledkem algoritmu Otsu je binární obraz, kde regionální maxima jsou vyznačena logickou jedničkou, a pozadí je vyznačeno logickou nulou, jak je možné vidět na obr. 5.5.



Obr. 5.5: Oblasti pro výpočet pozadí získané metodou Otsu

Pro vytvoření značek pozadí byly otestovány dvě metody. První z nich je založena na Dirichletově teselaci. Dirichletova teselace představuje proces vytvoření diagramu $V(P)$ který reprezentuje rozklad množiny bodů $P = \{p_1, p_2, \dots, p_n\}$ na n uzavřených či otevřených oblastí $V(p) = \{V(p_1), V(p_2), \dots, V(p_n)\}$ takových, že každý bod $q \in V(p_i)$ je blíže bodu p_i než k jakémukoliv bodu $p_j \in P$. Uzavřená oblast $V(p_i)$ se nazývá buňka. Pro libovolný bod $q \in V(p_i)$ a libovolnou buňku $V(p_j)$ musí platit:

$$d(q, p_i) \leq d(q, p_j), \quad (5.25)$$

kde d značí funkci vzdálenosti. Výsledek Dirichletovy teselace je vidět na obr. 5.6.




Obr. 5.6: Značky pozadí vytvořené za pomoci Dirichletovy teselace

Druhou metoda využívá distančního algoritmu. Distanční algoritmus se nejčastěji využívá na skeletonizaci postav lidí a zvířat ve videu. Při hledání linií značek pozadí jsme vyšli z algoritmu popsaného v pramenu [71], kde je popsán princip použití algoritmu na binární obraz tak, aby byla nalezena linie minimalizující funkce vzdálenosti od jednotlivých regionů. Výsledek tohoto algoritmu je uveden na obr. 5.7.




Obr. 5.7: Značky pozadí vytvořené pomocí distančního algoritmu

Při pohledu na výsledky testovaných metod zobrazené v obr. 5.6 a v obr. 5.7 je vidět, že Dirichletova teselace detekuje větší množství značek pozadí. To má za následek, že obraz je rozdělen do většího počtu oblastí. Při následném hledání objektů reprezentujícího kloubní hlavici je větší množství segmentovaných oblastí nežádoucí. Výhodnější se tedy jeví využití metody popsané v [71] využívající distančního algoritmu. Kromě menšího počtu segmentovaných částí dokáže tato metoda nalézt i bližší hranici okolo segmentované části kloubní hlavice jak je zvýrazněno v obr. 5.8. Při následné segmentaci pomocí metody rozvodí to umožňuje nalézt přesnější hranice kloubní hlavice.



Obr. 5.8: Ukázka značek pozadí v oblasti kloubní hlavice (vlevo - Dirichletova teselace, vpravo - distanční algoritmus [71])

Protože je však metoda rozvodí závislá hlavně na značkách popředí a značky pozadí pouze limitují oblast segmentace v daném regionu, jsou výsledky obou použitých metod v oblasti kloubní hlavice velmi podobné, jak je vidět na obr. 5.9.




Obr. 5.9: Ukázka segmentace kloubní hlavice (vlevo - Dirichtelova teselace, vpravo - Distanční algoritmus [71])

Segmentace kloubního disku, jak bude popsáno dále, vychází z jeho anatomických vlastností odvozených od okolní tkáně. To samozřejmě klade důraz na správnou segmentaci kloubní hlavice. Díky segmentaci kloubní hlavice dostáváme informace o trojrozměrném rozložení její tkáně v oblasti kloubu. Tato trojrozměrná informace je jednak velice důležitá jak pro vlastní tvorbu 3D modelu kloubní hlavice, tak i pro segmentaci tkáně kloubního disku. Tkáň kloubního disku představuje nejvýznamnější část čelistního kloubu, která také nejčastěji podléhá deformacím, což se neblaze projevuje právě na segmentaci.

5.2 Segmentace kloubního disku

Segmentace samotného disku je o mnoho složitější než segmentace kloubní hlavice. Disk není tolik kontrastní vůči okolí, jako je tomu u kloubní hlavice, a proto byla vytvořena metoda, která na základě zmenšování oblasti dokáže postupně vymezit prostor, ve kterém se disk s největší pravděpodobností pohybuje. Musíme si uvědomit, že oproti kloubní hlavici nemá kloubní disk tvarovou stálost a navíc jeho jasové vlastnosti jsou jen velmi málo odlišné od nejbližšího okolí, což ještě dále komplikuje všudypřítomný šum, který bylo možné odstranit jen částečně. Právě malá jasová a tvarová nestálost kloubního disku způsobuje to, že je složité ho segmentovat. Tvarová nestabilita způsobuje, že nelze využít algoritmů založených na detekci a rozpoznávání tvaru, jakými jsou například algoritmus typu ASM. Malá jasová odlišnost od okolní tkáně zase způsobuje nestabilitu algoritmů jako je metoda rozvodí použitá pro segmentaci kloubní hlavice. Další neblahá vlastnost souvisí s rozlišením obrazu, kdy celý kloubní disk je tvořen malým počtem pixelů, řádově několik stovek pixelů (u obrazů bez mikroskopické cívky) a okolo tisíce pixelů (u obrazů, kde byla použita mikroskopická cívka). To má za následek, že i malý počet chybně určených pixelů zavádí do výsledné segmentace velkou chybu. Právě pro tyto důvody byla vypracována metoda, která využívá anatomického uspořádání čelistního kloubu a zaměřuje se na možné fyzikální vlastnosti okolní tkáně tak, aby bylo možné s co nejvyšší pravděpodobností určit tkáň kloubního disku.


V první fázi metody byl pomocí analýzy anatomie vytvořen prostor, ve kterém se může disk pohybovat a to i disk, který může být defektní. Tento prostor vymezuje maximální oblast, kde se může fyzicky kloubní disk nacházet. Tato oblast byla zvolena na základě zkoumání anatomických vlastností kloubního disku a jeho fyzikální spojitosti s kloubní hlavicí. Kloubní hlavice zde hraje významnou roli jako počáteční bod, od kterého se oblast výskytu kloubní hlavice počítá a zároveň tvoří část hranice oblasti výskytu kloubního disku. Na obr. 5.10 je vidět geometrické omezení oblasti výskytu kloubního disku podle anatomického uspořádání čelistního kloubu. Jedná se o první oblast, která je navíc volena větší, aby bylo zaručeno, že se v ní kloubní disk skutečně bude nacházet. Jedná se tedy o kruhovou výseč se středem v kloubní hlavici, která začíná přímkou s úhlem 0° a končí přímkou s úhlem 225° . Velikost poloměru je dána trojnásobkem poloměru kloubní hlavice v rozmezí 0° - 135° až po pětinasobek v rozmezí 170° - 225° . Ve skutečnosti anatomické vlastnosti určují menší prostor a to od počátečního úhlu 85° , ale počítá se tam s diskem bez disfunkcí, které mohou disk vychýlit právě v oblasti nad kloubní hlavici. Tyto disfunkce jsou však tak nepravděpodobné, že algoritmus počítá s úhlem od 85° . Kloubní disk je na obrázku vykreslen zelenou barvou.



Obr. 5.10: Princip vymezení oblasti pravděpodobného výskytu disku.

Přestože známe anatomické uložení disku a jeho vlastnosti, je nutné si uvědomit, že pokud není použita mikroskopická cívka, tak oblast vymezená výsečí tvoří jen malé procento obrazu. Konkrétně pro standardní velikost obrazu 320x320 pixelů, tvoří vymezenou oblast pouhých 620 pixelů. To znamená, že prohledávaná oblast jednoho řezu tvoří pouhých 0,6% obrazu. Jedná se o velice malou oblast a chceme-li následně vytvořit 3D model kloubního disku, tak každý špatně identifikovaný voxel zanáší do 3D modelu tak obrovskou chybu, že výsledný model nemá dostatečnou vypovídací hodnotu. Při použití mikroskopické cívky se sice chybovost způsobená jedním voxellem snižuje na úroveň, která je už přijatelná, ale i tak je vysoká. Kromě malého rozlišení v osách x a y , je i malé rozlišení ve směru osy z , což znamená, že objekt disku se nachází jen v malém počtu řezů (průměrně se jedná asi o 7 řezů pro oba typy dat), což opět zanáší do tvorby 3D modelu obrovskou chybu. Velkou měrou tuto chybovost ovlivňuje šum, který se v obraze nachází a je složité ho odstranit. Pokud si uvědomíme, že oblast, ve které se snažíme segmentovat má pouhých 640 pixelů, potom jakýkoliv gradientní operátor, nebo filtr založený na konvoluční masce naprosto degraduje veškeré informace v prohledávané oblasti. Pokud bychom tuto oblast rozložili do čtverce, potom by se jednalo o obraz o rozměrech přibližně 25 x 25 pixelů. Pro data s využitím mikroskopické cívky je to přibližně 3000 pixelů, tedy oblast čtverce s hranou 55 pixelů. Tento malý prostor obsahuje pouze malé množství informace o dané tkáni, přesto se na základě tohoto malého počtu informací umí vyškolený odborník rozpoznat disfunkce čelistního kloubu. Samozřejmě nejsme schopni počítačovým zpracováním takto omezeného množství dat konkurovat vyškoleným odborníkům, a proto se jedná zaměřujeme na data získaná z MRI s mikroskopickou cívkou a dále je nutné data vždy kontrolovat, než se z nich zrekonstruuje 3D model. Přestože data bez mikroskopické cívky nemají dostatečné rozlišení pro relevantní 3D model pro oblast kloubního disku, lze na nich lépe demonstrovat použité metody, protože můžeme rozpoznat celý prostor hlavy a lépe se tak dá v tomto prostoru orientovat. To je také hlavní důvod, proč jsou tyto metody demonstrovány právě na datech bez mikroskopické cívky.

Disk a jeho vymezená oblast výskytu vykazují dvě hlavní vlastnosti, pomocí kterých se dá disk z vymezené oblasti oddělit. Musíme si uvědomit, že disk mění polohu i tvar v závislosti na tom, v jaké fázi se čelistní kloub nachází. Navíc jeho jasové hodnoty jsou velice blízké okolní tkáni, a proto je nutné zvolit uvážlivě ty vlastnosti kloubního disku, které jsou pro něj charakteristické, a které budou co možná nejvíce stálé.



Obr. 5.11: Vizualizace výřezu oblasti s diskem a návaznosti jednotlivých vrstev

První z nich je prostorový charakter disku. Protože jsou vybrány pouze řezy, na kterých je disk obsažen (určí se první a poslední), bude existovat vždy oblast, která bude navazovat na následující řez. Je vysoce nepravděpodobné, že by posun dalšího řezu, který je vzdálen pouhý milimetr, by byl natolik velký, že by na sebe části kloubního disku nenavazovali. Okolní tkáň samozřejmě v jednotlivých řezech taktéž navazuje, ale protože se v jednotlivých řezech více mění, než je tomu u kloubního disku je možné využít této vlastnosti k omezení oblasti, kterou prohledáváme. Vycházíme tedy ze statistických vlastností oblasti obsahující kloubní disk a kloubního disku v rovině z , tedy vlastnosti tkáňe mezi jednotlivými řezy. Předpokládáme, že v této statisticky testované oblasti existuje množina na sebe prostorově navazujících voxelů, které tvoří jádro kloubního disku procházející přes všechny řezy. Pokud bychom tento náš předpoklad vyjádřili statisticky, vycházíme ze střední hodnoty náhodné diskrétní veličiny a od ní odvozené směrodatné odchylky, která nám vyjadřuje míru kolísání okolo střední hodnoty. Právě míra kolísání od střední hodnoty nám nejlépe vystihuje vlastnost, kterou by měl vykazovat kloubní disk v oblasti, kde protíná všechny vrstvy. V první řadě je tedy nutné si vyjádřit střední hodnotu. Střední hodnota pro náhodnou diskrétní veličinu lze definovat jako [72]

$$E(X) = \sum_{x \in M} xp(x), \quad (5.26)$$

Od střední hodnoty je následně odvozen rozptyl ve tvaru:

$$D(X) = E\{[X - E(X)]^2\}, \quad (5.27)$$

Pokud se jedná o náhodnou diskrétní veličinu, jako je tomu v našem případě určíme rozptyl ze vztahu:

$$D(X) = \sum_{x \in M} [x - E(X)]^2 p(x), \quad (5.28)$$

Směrodatná odchylka diskrétní náhodné veličiny je pak definována jako [72]

$$\sigma(X) = \sqrt{D(X)}. \quad (5.29)$$

M nám definuje omezený prostor náhodné veličiny, který je v našem případě roven počtu řezů. Jako soubor náhodných pokusu slouží vždy hodnota voxelu o pevných souřadnicích řádku a sloupce. Vypočítá se tedy vždy směrodatná odchylka v ose z , pro pevně stanovený řádek a sloupec ve vymezeném prostoru kloubního disku. Pokud bychom ve vzorci za náhodnou veličinu x dosadili funkci voxelu $f(x,y,z)$, kde x už neznačí náhodnou veličinu, ale pozici v prostoru, potom by se směrodatná odchylka dala odvodit vztahy (5.30) a (5.31)

$$E(F(x, y, z)) = \sum_{z=0}^Z f(x, y, z)p(f(x, y, z)), \quad (5.30)$$


$$\sigma(F(x, y, z)) = \sqrt{\sum_{z=0}^Z [f(x, y, z) - E(F(x, y, z))]^2 p(f(x, y, z))}, \quad (5.31)$$

kde Z značí počet řezů. Pravděpodobnost výskytu $p(f(x, y, z))$, lze spočítat z histogramu obrazů ze všech řezů, kdy podělením četnosti počtem voxelů ve výběrové oblasti získáme přímo pravděpodobnost výskytu daného voxelu. Podělením histogramu celkovým počtem voxelů, dostaneme přímo pravděpodobnostní funkci. Aplikování výpočtu směrodatné odchylky v oblasti prohledávání se kontroluje, nakolik je tkáň v jednotlivých řezech podobná. Pokud převedeme $\sigma(F(x, y, z))$ na hodnoty jasu tak, že nejmenší směrodatná odchylka bude mít nejvyšší jasovou hodnotu, získáme 2D obrazový signál, kde nejvyšší jas značí nejvíce stálou oblast. Nejde o označení přímo kloubního disku, protože jeho poloha se v jednotlivých řezech vyvíjí a tudíž tato nejjasnější oblast obsáhne jen základní jádro, které odpovídá oblasti s nejvíce podobnými vlastnostmi. Toto jádro je společné pro většinu vrstev a dále nám slouží jako základ hledání disku. Můžeme si to dovolit právě díky jeho anatomickým vlastnostem, kdy kloubní disk má pouze omezenou oblast, ve které se může pohybovat a tato oblast je jen o něco málo větší, než je samotný disk. To zaručuje s velmi vysokou pravděpodobností, že existuje oblast kloubního disku, která je viditelná minimálně přes 90% vrstev.




Obr. 5.12: Pravděpodobnostní model spojitosti jednotlivých řezů

Ukázka pravděpodobnostního modelu prostorové spojitosti je na obr. 5.12, kde nejtmařejší oblast zobrazuje nejmenší pravděpodobnost prostorové spojitosti disku a nejsvětlejší oblast vyznačuje nejvyšší pravděpodobnost prostorové spojitosti. Disk samozřejmě není ve všech řezech spojitý, a proto se volí práh určující, jak vysoká pravděpodobnost splňuje ještě pravděpodobnost výskytu disku a jaká nikoliv. V této části algoritmu se snažíme nalézt nejpravděpodobnější oblast výskytu disku pro všechny vrstvy. Abychom měli jistotu, že se do oblasti nezahrnou i oblasti, které disku nepatří, sníží se výsledná maska pomocí algoritmu eroze. Díky znalosti polohy jádra pro všechny vrstvy jsme schopni identifikovat statisticky jasové vlastnosti disku, které můžeme následně využít pro další zpracování.




Obr. 5.13: Maska jádra kloubního disku, která je společná pro všechny vrstvy

V současné chvíli známe přibližné statistické jasové vlastnosti oblasti disku, které jsou společné pro všechny vrstvy. Znalost těchto vlastností se nám bude hodit jako základ pro druhou část vlastností kloubního disku, která se zaměřuje na jednotlivé vrstvy a rozložení jasu v osách x a y . Stále zde pracujeme pouze s omezeným prostorem, který vychází z anatomických vlastností. Zde je patrné, že kloubní disk se nachází v určitém prostoru ohraničeném tkání (kloubní hlavici, kloubní jamkou atd.). Části jako kloubní hlavice a kloubní jamka vykazují jednoznačně vyšší jasové hodnoty než je tomu u kloubního disku a jeho bezprostředního okolí, a proto je jednoduché je odseparovat použitím prahování se správně zvoleným prahem. Ve výsledném obraze nám tedy zůstanou pouze měkké tkáně a prostor v okolí disku, ve kterém se pohybuje. Tímto jsme dospěli do situace, kdy se snažíme oddělit od sebe dvě oblasti o různých statistických vlastnostech. Bohužel co se týká jasových vlastností, jsou si tyto oblasti velice blízko a hlavně v hraničních částech se překrývají. Jako nejlepší statistické vyjádření sledované oblasti je histogram, který můžeme vidět na obr. 5.15. Protože obě oblasti jsou si jasově velice podobné, nelze je oddělit pouhým prahováním, protože by to mělo za následek velkou chybovost v oblasti disku. Proto byla vyvinuta metoda, která dokáže určit oblast s diskem a na základě analýzy dat v histogramu oddělit oblast s diskem. Jedná se vlastně o inverzní algoritmus, který předpokládá, že obě části vykazují určité statistické vlastnosti. V předchozí části jsme zjistili statistické vlastnosti jádra disku a to hlavně rozdělení pravděpodobnosti. Jednalo se sice o malý soubor dat, ale přesto při zjednodušení vykazoval přibližné Gaussovské rozdělení. Pokud pro zjednodušení budeme předpokládat, že i okolí disku vykazuje přibližně Gaussovské rozdělení, můžeme inverzně hledat kombinace dvou Gaussových křivek, tak aby se co nejvíce přiblížili tvaru získaného histogramem.




Obr. 5.14: Grafické vyjádření problému segmentace disku pomocí histogramu

Jak je vidět na obr. 5.14, tak vstupními daty jsou obraz disku označený jako I_1 a obraz jeho okolí označený jako I_2 . Tyto objekty se dají převést do tvaru histogramu vyjadřujícím jejich statistické vlastnosti, jak je naznačeno v prvním bloku. Dalším blokem je naznačeno, že oba obrazy obsahují určitý aditivní šum V , který je do každého obrazu superponován a zkresluje jejich statistické vlastnosti. My nyní máme výstupní obraz O , který obsahuje oba tyto objekty i aditivní šum. Naším cílem je nalézt původní obrazy I_1 a I_2 . Inverzní algoritmus využívá tvarů Gaussových křivek, kterými lze reprezentovat statistické vlastnosti obou objektů. Podstata spočívá v modelování Gaussových křivek a jejich superpozice. Protože se objekty nepřekrývají, dochází pouze k lineárnímu navýšení statistických dat, pro které lze využít principu superpozice. Příklad histogramu výstupního obrazu O , je vidět na obr. 5.15. Protože histogram přímo souvisí s pravděpodobnostní funkcí, kterou lze modelovat na základě Gaussových křivek je možné vytvářet tyto křivky a jejich superpozici porovnávat s pravděpodobnostní funkcí výsledného obrazu.



Obr. 5.15: Histogram mezikružím omezené části obrazu

Pokud pro zjednodušení zanedbáme aditivní šum, potom můžeme celý inverzní problém řešit jako prohledávání parametrů dvou Gaussových křivek v uzavřeném prostoru tak, abychom minimalizovali vzdálenost mezi jejich superpozicí a pravděpodobnostní funkcí výseče MRI obrazu. Složkou, která může ovlivňovat tvar Gaussovy křivky a její parametry pro jednotlivé objekty je aditivní šum. Abychom zjistili jeho statistické vlastnosti, zaměřili jsme se na oblast obrazu, která by měla být homogenní. Jedná se o oblast mimo vlastní měřenou tkáň, kde se nachází pouze vzduch, který by měl vykazovat nulový signál a tím by tato oblast měla být nejtmařejší a zároveň homogenní. Právě vliv šumu ovlivní tuto oblast tak, že se nejedná o homogenní oblast, ale má určité charakteristické statistické vlastnosti, které nám mohou přiblížit vlastnosti šumu. Analýzou těchto statistických vlastností, získáme přehled, nakolik tento aditivní šum ovlivní statistické vlastnosti segmentovaného kloubního disku. Ukázka měřených statistických vlastností aditivního šumu je vidět na obr. 5.16.



Obr. 5.16: Ukázka pravděpodobnostní funkce šumu z oblasti označené na MRI

Jak je vidět na obr. 5.16 funkce pravděpodobnosti získaná z oblasti, která by měla mít nulovou hodnotu, vykazuje přibližně Gaussovské rozdělení pravděpodobnosti se střední hodnotou 8,7 a směrodatnou odchylkou 4,8. Směrodatná odchylka šumu je nízká a šum ovlivňuje oba objekty, které chceme od sebe odseparovat statisticky stejně. To znamená, že se projeví v obou objektech přibližně stejným způsobem a právě z důvodu malé směrodatné odchylky ovlivní výsledný tvar jednotlivých křivek jen nepatrně. Z výsledků získaných analýzou šumu vyplývá, že neovlivní tvary křivek natolik, abychom pomocí jejich modelování nedostali relevantní výsledky. Z těchto důvodů se vliv šumu v navazujících výpočtech zanedbává.

Nyní tedy můžeme modelovat dané křivky a porovnávat je s pravděpodobnostní funkcí získanou histogramem. Samozřejmě lze tento problém řešit validací přes celý prostor. Tato varianta je však velice neefektivní. Protože se jedná o rozsáhlý prostor a průchod přes všechny jeho varianty by zabral zbytečně velké množství systémových prostředků. Z rozboru charakteru minimalizace funkce se dá usoudit, že by optimalizace mohla být provedena pomocí principu evolučních technik. Obecně se evoluční techniky dají použít na jakýkoliv optimalizační problém hledání extrémů. Každý optimalizační problém lze vyjádřit jako

problém geometrický, kdy se jedná o hledání nejvyššího (maximum), nebo nejnižšího (minimum) bodu na N rozměrné ploše [73]. Vyjdeme-li ze základních podmínek definovaných v [73] pro testovací funkce evolučních algoritmů:

- graf funkce nemá fraktální charakter,
- jsou definovány na reálných, celočíselných nebo diskrétních argumentech,
- jsou multimodální,
- jsou nelineární,

můžeme určit, zda tento problém opravdu patří do skupiny, kterou je možné zařadit do problému optimalizace řešitelné pomocí evoluční techniky.

Podle charakteru minimalizace funkce se pro optimalizaci hodí genetický algoritmus, kde pro generování směsí Gausových křivek se vychází z definice funkce normálního rozdělení pravděpodobnosti

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (5.32)$$


kde σ je směrodatná odchylka a μ je střední hodnota. Touto funkcí se dají generovat jednotlivé pravděpodobnostní funkce normálního rozložení pravděpodobnosti. Směs těchto Gausových křivek lze definovat vztahem:

$$p_k(x) = \sum_{k=1}^K \omega_k f_k(x). \quad (5.33)$$

Jednotlivé genomy jsou generovány jako matice o velikosti 2×3 , kde jednotlivé sloupce budou obsahovat parametry μ , σ , ω každé ze dvou Gausových křivek. Abychom mohli použít genetický algoritmus, je nutné určit tzv. vhodnost [73] jedince (v anglické literatuře označována jako fitness funkce). Kvalita neboli vhodnost jednotlivých genomů se určuje pomocí účelové funkce, která je zde počítána jako chyba nejmenších čtverců k aproximaci histogramu pravděpodobnostní funkcí a lze definovat vztahem


$$LSE = \sum_{i=1}^n (\tilde{y}_i - y_i)^2, \quad (5.34)$$

kde \tilde{y}_i je odhadovaná hodnota pravděpodobnostní funkce, y_i je hodnota pravděpodobnostní funkce získaná aproximací z histogramu obrázku. Hodnota n značí počet jasových složek, určujících délku histogramu. Aby bylo možné určit složitost a další vlastnosti prohledávané oblasti, je možné to ukázat na zjednodušeném příkladě, kdy směrodatnou hodnotu a četnost necháme konstantní a budeme hledat pouze v podprostoru střední hodnoty. Tím se nám problém z prostoru o velikosti $N = 9$ sníží na problém $N = 2$, který je možné graficky vyjádřit. Příklad takto zjednodušeného systému vyjádřeného směsí gausových křivek je vidět na obr. 5.17.



Obr. 5.17: Příklad směsi dvou Gausových křivek s konstantní směrodatnou odchylkou a četností

Vydeme-li z toho, že hledáme minimum hodnoty LSE, potom je funkci podprostoru, kde se prohledává možné vyjádřit graficky jak je vidět na obr. 5.18.




Obr. 5.18: Graf funkce prohledávaného podprostoru

Z grafu funkce prohledávaného podprostoru tvořeného středními hodnotami a LSE je vidět, že jeho charakter nevykazuje fraktální charakter, je multimodální (obsahuje více extrémů) a je nelineární. Navíc jsou argumenty definovány v reálných číslech. Jedná se tedy o optimalizační funkci, u které je objektivní využít pro optimalizaci pomocí evolučních technik. Při rozšíření na $N = 9$ prostor se složitost exponenciálně zvýší, ale vlastnosti zůstanou nezměněny. Úkolem navrženého a dále popsaného genetického algoritmu je tedy nalézt alespoň jedno globální minimum. Z grafu je patrné, že existují dvě. Vychází se z prostoru pro střední hodnoty, kdy existují kombinace v pořadí první křivka s druhou, nebo druhá s první. To znamená, že i v prostoru $N = 9$ se budou nacházet dvě minima, kdy obě budou udávat správné řešení kombinace dvou gausových křivek. Rozpoznání, která z křivek je reprezentací kloubního disku se stanovuje na základě statistických vlastností získaných analýzou jádra (viz obr. 5.13). Abychom však zjednodušili prohledávaný prostor, lze ho omezit tak, že bude obsahovat pouze jedno minimum. Dvě minima vznikají tak, že může nastat kombinace první křivka s druhou, nebo opačně druhá křivka s první pokud se na tento problém díváme z pohledu uložení parametrů křivek v matici (první druhá). Abychom omezili prostor pouze na jedno minimum, musíme rozsah prohledávaného prostoru omezit tak, že se vytvoří závislost mezi křivkami. Protože se jedná pouze o směr posunu v ose μ , jde pro střední hodnoty obou křivek zavést podmínku, která dynamicky omezí prostor obou křivek tak, že nedojde k jejich záměně v prostoru a tím se omezí prostor pouze na jedno minimum. Podmínka omezující prostor je dána vztahem:

$$0 \geq \mu_1 > \mu_2 \geq l, \quad (5.35)$$

kde l značí maximální hodnotu danou velikostí prohledávaného prostoru v ose x . Protože je pravděpodobnostní funkce odvozena od histogramu obrazu bude tato funkce nabývat hodnot od 0 do maximální jasové hodnoty, která je pro 12 bitové číslo rovna 4095. Protože se jedná pouze o idealizovaný stav a pro lepší názornost je velikost na osách μ_1 a μ_2 zmenšena pouze do prostoru, kde se nachází minima. Pokud omezíme prostor podmínkou (5.35), potom jeho tvar vypadá dle obrázku obr. 5.19. Na grafu je vidět, že minimum zde vykazuje pozvolný charakter a v oblasti, kde se hodnoty μ_1 a μ_2 přibližují, vzniká prudký přechod mezi minimem a maximem. Jedná se samozřejmě o idealizovanou funkci, kde je pro modelování histogramu vytvořena pravděpodobnostní funkce tvořená ideálními gausovými křivkami, jak je znázorněno na obr. 5.17 což v praktickém použití vyjde pouze v minimu případů a v okolí globálního minima se bude s určitostí nacházet několik lokálních minim, do kterých může část generace genetického algoritmu konvergovat. Genetický algoritmus nezaručí, že výsledné řešení je to nejlepší. Jde spíše o nalezení dostatečně dobrého řešení pro daný optimalizační problém. To jak dobré řešení má být nalezeno, lze ovlivnit parametrem hraniční hodnoty funkce „vhodnosti“. Může se však stát, že daný algoritmus nemusí nikdy dojít k této hodnotě a může konvergovat v některém z lokálních minim okolo globálního minima. Navíc stanovení hraniční hodnoty funkce „vhodnosti“ pro každou vrstvu je velice obtížné. Aby nedocházelo k zacyklení algoritmu, kdy může být nereálně dosáhnout stanovené hraniční hodnoty, je nutné omezit počet generací, po kterých se algoritmus zastaví a jako výsledek se zvolí nejlepší dosažené řešení.



Obr. 5.19: Graf funkce omezeného prohledávaného podprostoru.

Protože je genetický algoritmus navržený tak, že se hledá maximum, jak je popsáno v pramenu [73], je nutné při hledání minima přepočítat tuto funkci. Tento přepočet lze schématicky zapsat jako [73]

$$\text{pro } \forall ind_1, ind_2 \in R, f(ind_1) \leq f(ind_2) \Rightarrow F(ind_1) \geq F(ind_2), \quad (5.36)$$

kde ind je jedinec z populace, f je účelová funkce a F je funkce počítající vhodnost. Z praktického hlediska se přepočítá hodnota vhodnosti do normalizovaného tvaru v intervalu $[0,1]$. Vyjdeme-li z toho, že maximální hodnotě vhodnosti přiřadíme minimální funkční hodnotu účelové funkce a minimální hodnotě vhodnosti přiřadíme maximální hodnotu účelové funkce, potom ostatní hodnoty se lineárně přerozdělí mezi tyto krajní body [73]. Tato transformace lze vyjádřit vztahem


$$F(ind) = \frac{F_{\max} - F_{\min}}{f_{\min} - f_{\max}} f(ind) + \frac{f_{\min} F_{\min} - f_{\max} F_{\max}}{f_{\min} - f_{\max}}, \quad (5.37)$$

kde f_{\max} je maximální hodnota účelové funkce, f_{\min} je minimální hodnota účelové funkce, F_{\max} je maximální hodnota vhodnosti, F_{\min} je minimální hodnota vhodnosti. Funkce $f(ind)$ a $F(ind)$ značí hodnotu účelové funkce aktivního jedince a vhodnost aktivního jedince.

Pro volbu rodičů byla použita pořadová selekce reprezentovaná funkcí

$$F(ind_n) = L \frac{1}{\sqrt{n}}, \quad (5.38)$$

kde n určuje pořadí jedince v lineárně uspořádané generaci podle funkce vhodnosti, kterou se snažíme minimalizovat. L nám určuje rozsah skóre, které může daný jedinec získat. Graf škálovací funkce je vidět na obr. 5.20. Tento tvar přepočtu byl zvolen záměrně, protože udržuje dostatečně rozmanitou populaci. Pokud by byl vybrán jen vzorek, jak je tomu u metody selekce nejvyšších N jedinců z populace, může dojít k tomu, že populace nebude dostatečně rozmanitá a zvýší se pravděpodobnost konvergence algoritmu v lokálním minimu. Naopak pokud zase zvolíme rovnoměrný výběr ze všech rodičů, bude rozmanitost příliš velká a sníží se tak schopnost algoritmu rychlé konvergence, protože generace budou ovlivněny příliš vysokou variabilitou. Oproti úzké volbě má tato funkce selekce vyšší variabilitu a přitom si zachovává dostatečnou míru schopnosti konvergence k minimu.



Obr. 5.20: Ukázka funkce selekce pro přepočet vhodnosti jedinců na skóre

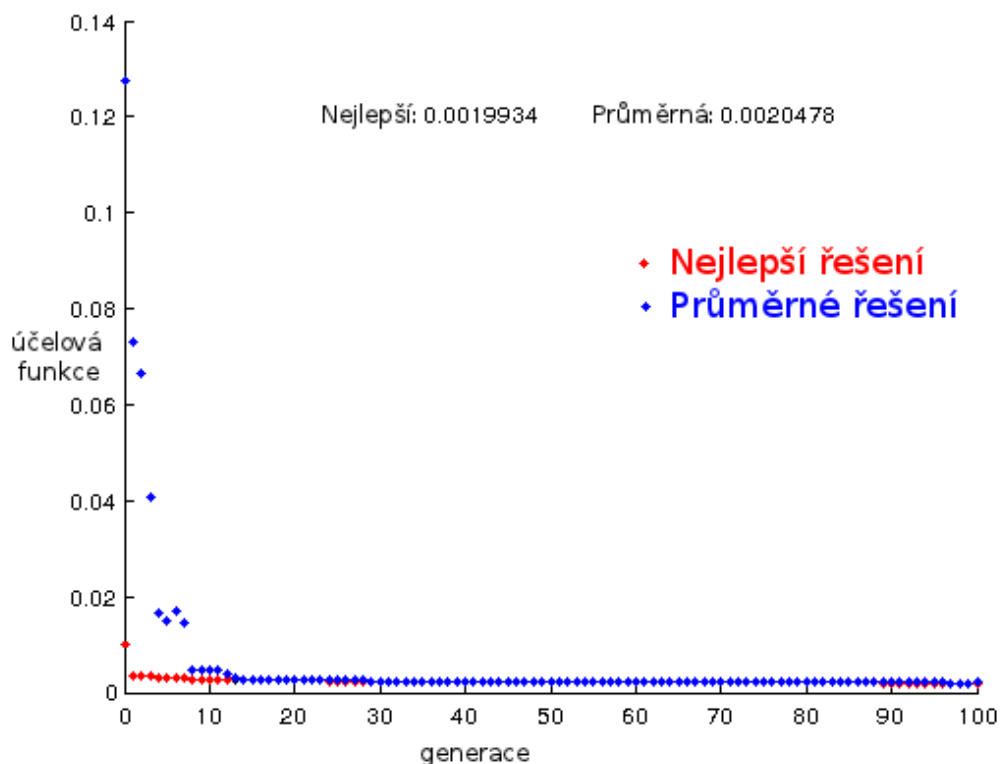
Jak je vidět z funkce selekce, zvolená velikost jedné generace je rovna 20 jedinců. Maximální počet generací byl omezen na 100. Ve zvoleném genetickém algoritmu byl nastaven systém elitismu na 10% populace, což při počtu 20 jedinců v populaci činí elitními dva jedince, kteří automaticky přecházejí do další populace. To umožňuje udržet nejlepší řešení z každé populace, pro další generace. Významnými operacemi s jedinci v genetickém algoritmu jsou

- **Křížení:** Pro křížení byl využit rozptýlený algoritmus, kdy se náhodně vygeneruje binární vektor, kde 1 reprezentuje zachování hodnoty z prvního rodiče a 0 reprezentuje zachování hodnoty z druhého rodiče.
- **Mutace:** Pro mutaci bylo využito Gausovy mutace, kdy gausova funkce, ze které se vybírá má střední hodnotu rovnu 0 a směrodatná odchylka této distribuce je odvozena od každé generace podle vztahu

$$\sigma_k = \sigma_{k-1} \left(1 - s \frac{k}{generace} \right), \quad (5.39)$$


kde s značí parametr rychlosti zmenšování směrodatné odchylky a parametr generace reprezentuje rozsah velikosti jednotlivých chromozomů pro danou generaci.

Tímto je nadefinován kompletní genetický algoritmus. Pro analýzu prohledávané oblasti, byla zvolena hraniční hodnota účelové funkce na hranici možností systému, proto se často výsledek rovnal nejlepšímu řešení při průběhu přes 100 generaci. Jak je vidět z grafu na obr. 5.21, tak systém rychle konverguje k minimu a změna účelové funkce je od 30 generace minimální. Přesto je vidět, že pravděpodobně díky mutaci je možné i v 90 generaci vytvořit lepší jedince.




Obr. 5.21: Graf vývoje účelové funkce po 100 generacích genetického algoritmu pro 2 Gausovy křivky

Výsledkem takto získaného řešení jsou dvě gausovy křivky, jejichž kombinace nejlépe odpovídá pravděpodobnostní funkci získané z histogramu prohledávané oblasti. Tvar těchto křivek je vidět na obr. 5.22.




Obr. 5.22: Příklad Gausových křivek získaných pomocí genetického algoritmu

Protože pravděpodobnostní funkce získaná z histogramu obrazu je ovlivněna aditivním šumem a vykazuje pouze přibližný charakter superpozice Gausových křivek. Nemůže být nalezené řešení stejné, jako tomu bylo u testovací funkce, kdy jsme simulovali pravděpodobnostní funkci obrazu směsí Gausových křivek. Pomocí tohoto algoritmu lze dosáhnou 84% podobnosti při použití dvou Gausových křivek. Na obr. 5.23 je vidět porovnání generované směsí Gausových křivek s pravděpodobnostní funkcí získanou z obrazu.



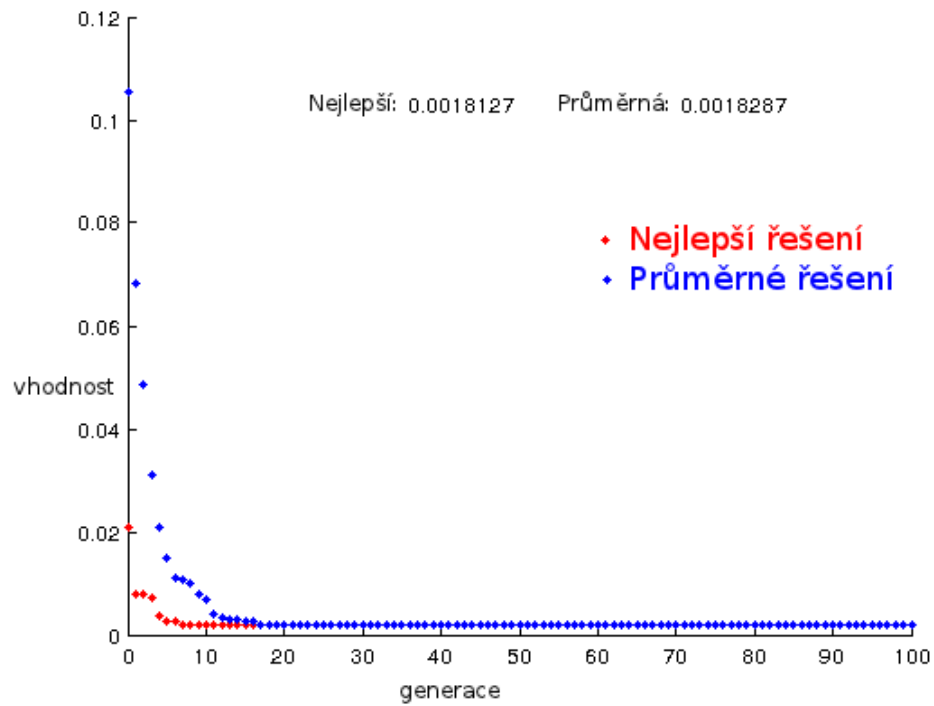
Obr. 5.23: Porovnání pravděpodobnostní funkce histogramu (zelená) se směsí dvou nalezených Gausových křivek (modrá)

Při modelování pravděpodobnostní funkce histogramu jsme vycházeli z předpokladu, že se skládá ze dvou hlavních složek, kde každá vykazuje Gausovské rozložení pravděpodobnosti. Aby bylo možné podpořit tuto hypotézu, byl daný algoritmus otestován s větším počtem Gausových křivek. Právě větším počtem Gausových křivek lze modelovat různé pravděpodobnostní charakteristiky daných tkání, nebo větší počet tkání s gausovským rozdělením pravděpodobnosti. Výsledkem by tedy mělo být významné zlepšení účelové funkce a tím tedy parametru vhodnosti nejlepšího jedince. Naopak mírným zlepšením se projeví vliv aditivního šumu, který ovlivňuje tvar histogramu, a který je obsažený v celém obraze. Aby byl výsledek relevantní bylo otestováno rovnou pět Gausových křivek. Na obr. 5.24 je vidět porovnání směsi pěti Gausových křivek s pravděpodobnostní funkcí histogramu. Přesnost se zvýšila na 85,5% což je velice malé zvýšení přesnosti, pokud si uvědomíme, že se počet křivek zvýšil 2,5x. Výsledek měření tedy ukazuje, že náš předpoklad byl skutečně relevantní a je tedy možné modelovat pravděpodobnostní funkci kloubního disku a jeho okolí pomocí pouze dvou Gausových křivek.




Obr. 5.24: Porovnání pravděpodobnostní funkce histogramu (zelená) se směsí pěti nalezených Gausových křivek (modrá)

Jak se dalo předpokládat při hledání většího počtu křivek, vzroste i prohledávaný prostor. To má za následek pomalejší konvergenci k minimu, vyplývající z větší rozmanitosti v počáteční populaci. Přesto i zde je konvergence k minimu dostatečně rychlá a je vidět, že ani zde se nepodařilo dosáhnout požadované přesnosti účelové funkce a výsledek byl získán po dokončení 100 generací (obr. 5.25). Na základě výsledků z obr. 5.26 lze usoudit, že přesnost se zlepšila hlavně v oblasti přesnosti modelování zeleně označené křivky z obr. 5.22. Protože je zde tato křivka modelována množstvím křivek podobných vlastností, lze usuzovat, že se jedná jen o malé odchylky, což koresponduje s malou hodnotou zvýšení přesnosti modelované směsi s pravděpodobnostní funkcí histogramu.



Obr. 5.25: Graf vývoje účelové funkce po 100 generacích genetického algoritmu pro 5 Gausových křivek




Obr. 5.26: Ukázka pěti Gausových křivek získaných pomocí genetického algoritmu

Otestováním modelování pomocí většího počtu Gaussových křivek bylo ukázáno, že opravdu se jedná o dvě tkáně s přibližným Gaussovským rozdělením pravděpodobnosti a že při použití dvou Gaussových křivek dostaneme dostatečně přesné výsledky ve velice krátkém čase. Vlastní segmentace objektu následně probíhá tak, že jako základ je použito jádro získané analýzou vlastností jasových složek v navazujících vrstvách. Díky takto získaným statistickým informacím o vlastnostech jádra můžeme určit, která z křivek reprezentuje kloubní disk. Vlastní segmentace probíhá tak, že se zvětšuje oblast jádra kloubního disku, tak, že se nejprve berou v úvahu pixely v nejbližším okolí s nejbližší jasovou hodnotou a takto se pokračuje do doby, kdy se histogram obrazu nejvíce přiblíží modelované křivce. Pro měření podobnosti mezi histogramem a křivkou je stejně jako u genetického algoritmu využito vztahu (5.34). Opět se tedy jedná o minimalizaci funkce, avšak s velmi malým rozměrem prohledávané oblasti, a proto není potřeba využít optimalizačních algoritmů.

5.3 Tvorba 3D modelu

Výsledkem segmentace je binární maska, která určuje pozici kloubního disku, v jednotlivých vrstvách, získaných pomocí NMR. Z pohledu dat se jedná o segmentované voxely, které spolu sousedí v kartézském souřadnicovém systému. Přestože NMR pracuje v kartézském souřadnicovém systému, neznamená to, že jednotlivé vrstvy jsou kolmé k jeho osám. Ve skutečnosti jsou jednotlivé vrstvy natočeny pod určitým úhlem a hrany voxelu nejsou rovnoběžné se souřadnicovým systémem. Vidět je to při pohledu na různé roviny řezů jak je to vidět na obr. 5.27.



Obr. 5.27 Ukázka vzájemné polohy řezů mezi sagitální a koronální rovinou

Řezy sice nejsou kolmé na souřadný systém, ale vzájemně jsou rovnoběžné a jednotlivé vrstvy nejsou vzájemně posunuté, to zaručuje návaznost jednotlivých vrstev. Vzhledem k tomu, že transversální směr se pro diagnózu kloubního disku nepoužívá a v koronálním směru je velice obtížné i pro radiologa určit tkáň kloubního disku, je segmentace omezena pouze na sagitální rovinu řezů. Tímto omezením odpadá potřeba registrace voxelů, které na sebe navazují v různých směrech pro různé roviny řezů a jejich přizpůsobení v prostorovém uspořádání, tak aby si odpovídaly. Jak je patrné z obr. 5.27, kde světle modrá barva reprezentuje hraniční řezy v sagitální rovině a tmavě modrá barva určuje polohu aktuálního řezu v sagitální rovině, vzájemná poloha rovin řezů je skutečně rovnoběžná. Matematicky lze dokázat rovnoběžnost řezů, vzájemnou polohou jejich normálových vektorů. Označíme-li si dva sousední řezy jako roviny ρ a ψ potom jejich vzájemná poloha odpovídající rovnoběžnému stavu nastává za podmínky

$$\rho \cap \psi = \emptyset \quad (5.40)$$

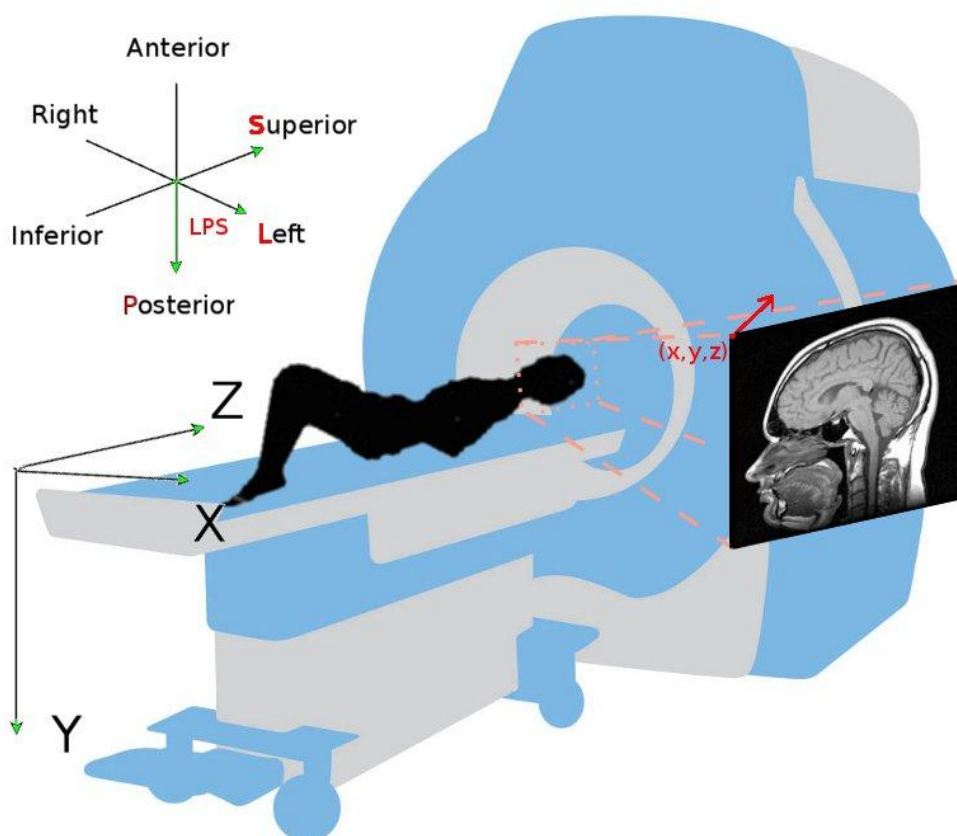
a musí platit, že jejich normálové vektory n_ρ a n_ψ v jednotkovém tvaru si musejí odpovídat. V DICOM souboru je pozice řezu uložena ve třech parametrech, které jsou uloženy v souboru pod štítky (v anglické technické dokumentaci označovány jako tag). Každý štítek má dva identifikátory, pomocí kterých se dá konkrétní štítek nalézt. Pro identifikaci polohy voxelu v prostoru se používají tyto štítky

- *Image Position (Patient) (0020,0032)* obsahuje tři čísla, které odpovídají x,y,z pozici v mm levého horního voxelu daného řezu,
- *Image Orientation (Patient) (0020,0037)* obsahuje šest čísel, kterými lze definovat vektor určený cosinem úhlu levého horního bodu vůči osám souřadného systému. Jedná se tedy o normálový vektor poloroviny řezu.
- *Patient Position (0018, 5100)* obsahuje zkratku slov určující polohu pacienta vůči deskriptoru tomografu. Zkratka se skládá ze dvou až čtyř písmen, kde první dvě určují, zda je pacient natočen hlavou napřed (HF-Head First), nebo nohama napřed (FF- Feet First) a další jedno nebo dvě písmena určují polohu natočení. U kloubního disku je zkratka HFS (Head First-Supine), což znamená, že pacient je orientován hlavou napřed a leží na zádech.

Třetí štítek určující pozici pacienta je důležitý pro určení polohy pacienta vůči souřadnému systému vycházejícímu z pozice LPS (Left, Posterior, Superior). Systém záznamu pozice voxelu je graficky znázorněn na obr. 5.28. Z obrazu je patrné, že pokud máme určit zda jsou jednotlivé řezy skutečně rovnoběžné, je důležitým parametrem štítek *Image Orientation*, který určuje pozici poloroviny vůči počátku souřadnic. Tab. 5.1 ukazuje hodnoty štítků *Image Orientation* a *Image Position* pro první tři řezy. Z hodnot je patrné, že pro normálový vektor je pro všechny řezy totožný, což znamená, že se jedná o rovnoběžné, nebo totožné roviny. Abychom vyloučili možnost, že se jedná o totožné roviny, je nutné splnit podmínku (5.40), tedy, že nemají společný bod. Za předpokladu, že se jedná o rovnoběžné, nebo totožné roviny, postačí nalézt bod, který je průsečíkem roviny s přímkou, která je na ni kolmá. Jak je patrné z obr. 5.27 souřadnice takového průsečíku jsou uloženy ve štítku *Image Position*. Jak je vidět v tab. 5.1 souřadnice tohoto průsečíku v různých řezech se liší, takže se skutečně nejedná o totožné roviny.


Tab. 5.1: Hodnoty štítků Dicom souboru pro jednotlivé řezy

Pořadí řezu	Image Position	Image Orientation
1.	-21.8625\ -107.8150\80.2448	-0.2097\0.9755\0.06502\0.02951\0.0727\ -0.9969
2.	-24.1104\ -108.2914\80.1434	-0.2097\0.9755\0.06502\0.02951\0.0727\ -0.9969
3.	-26.3581\ -108.7679\80.0422	-0.2097\0.9755\0.06502\0.02951\0.0727\ -0.9969



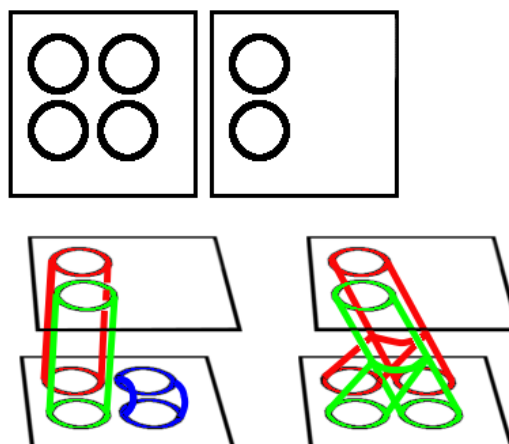
Obr. 5.28: Princip ukládání pozice voxelů pro jednotlivé řezy MRI

Nyní už máme splněnu podmínku pro tvorbu polygonálního modelu. Pro jeho tvorbu je standardem považována metoda Marching Cubes [75] s plnou tabulkou umožňující jednoznačné určení hraničních pozic kostek. Jako vstupní data této metody se užívají binární masky tkání získané segmentací. Další výhodou využití této metody je možnost porovnání kvality vzniklých 3D modelů, protože byla pro tyto účely vytvořena a existuje už velké množství takto vytvořených dat. Aplikováním této metody na segmentovaná data jsme získali 3D modely, jako je vidět například model kloubní hlavice na obr. 5.29.



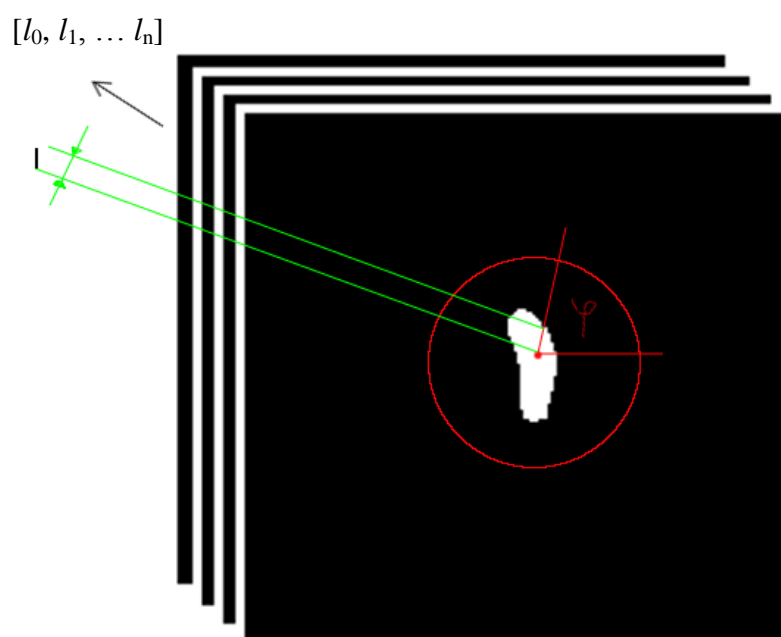
Obr. 5.29: 3D model při základním použití metody Marching Cubes

Protože v ose z je obraz významně podvzorkovaný oproti osám x a y , dochází k jevu, kdy přechody mezi jednotlivými vrstvami nejsou plynulé, ale dochází u nich ke skokovitému nárůstu hodnoty mezi jednotlivými řezy. To samozřejmě působí velice nepřírozně a zkresluje to výsledný obraz. Hlavním důvodem je nerovnoměrné rozlišení obrazů mezi jednotlivými osami, kdy v osách x a y je vzorkování vyšší a v ose z je vzorkování nižší a tím dochází k tomuto jevu. V použitém obraze máme rozlišení v osách x a y rovno 2,133 pixelu na milimetr, v ose z je to 0,43 pixelu na mm, což je přibližně 5x menší rozlišení. Vliv menšího rozlišení je patrný hned prvním okem, kdy je vidět, že samotný model je příliš tenký a neodpovídá skutečnosti. Špatná velikost v ose z 3D modelu je způsobena tím, že vlastní kostka je krychle, tedy, že se počítá s tím, že se zpracovávají data, kde máme totožné rozměry ve všech osách. Samozřejmě v dané ose z , lze obraz transformovat přes afinní transformační matici, pomocí které lze rozměry modelu dorovnat. To však způsobí pouze natažení modelu a nevyřeší to problém s nízkou vzdáleností mezi snímky. Musíme si uvědomit, že ve skutečnosti existuje neurčitost mezi snímky, která může být příčinnou nepřesnosti 3D modelu. Tato neurčitost je způsobena neznalostí dat mezi jednotlivými snímky a nelze ji tedy úplně odstranit. Míra neurčitosti mezi snímky je velmi závislá na tvaru objektu. Jak je vidět na obr. 5.30, mezi dvěma navazujícími řezy může existovat větší množství řešení.



Obr. 5.30: Grafické vyjádření neurčitosti mezi jednotlivými řezy

V našem případě je množství neurčitosti menší, protože návaznost snímků je vysoce pravděpodobná. Toho můžeme využít a pro zvýšení rozlišení v ose z , kde se nabízí použití kubické interpolace. Abychom vyšli z tvaru objektu a co nejvíce využili jeho tvarových vlastností, najdeme těžiště mediánu všech řezů. Od tohoto těžiště vedeme přímky v intervalu od 0° do 360° . Na těchto přímkách hledáme hranice objektu pro jednotlivé řezy. Výpočtem mediánu binárních masek jednotlivých vrstev dostaneme výslednou masku, kde je možné výpočtem těžiště určit místo, které je společné pro všechny vrstvy, a z kterého je možné tyto hranice objektů hledat. Je důležité, aby to místo bylo pro všechny vrstvy stejné, aby bylo možné následně dopočítat pozici těchto hranic. Pro přepočítání mezilehlých masek a tím navýšení rozlišení v ose z , vycházíme z nalezených bodů, které přepočítáváme pomocí kubické interpolace. Princip je znázorněn na obr. 5.31. Zde je také možné vidět, že pro každý úhel φ se počítá vzdálenost l pro jednotlivé řezy. Vznikne tak jednorozměrná řada délek, kterou je možné interpolovat pomocí kubické interpolace.



Obr. 5.31: Grafické vyjádření principu interpolace v ose z

Pro zvýšení rozlišení v ose z s ohledem na tvarovou kontinuitu v této ose, byla pro výpočet hraničních bodů objektů v mezilehlých snímcích použita metoda kubické interpolace. Tato metoda vychází z polynomu třetího stupně a jeho derivace. Tvar vzorce polynomu třetího stupně, ze kterého vychází kubická interpolace [76] je

$$f(x) = ax^3 + bx^2 + cx + d \quad (5.41)$$

a jeho derivace je

$$\dot{f}(x) = 3ax^2 + 2bx + c. \quad (5.42)$$

Proměnná x nám v daném případě značí hodnoty vzdálenosti l hranice objektu od těžiště. Hodnoty polynomu a jeho první derivace při $x = 0$ a $x = 1$ jsou

$$f(0) = d \quad (5.43)$$

$$f(1) = a + b + c + d \quad (5.44)$$

$$f'(0) = c. \quad (5.45)$$

$$f'(1) = 3a + 2b + c. \quad (5.46)$$

Tyto rovnice se dají přepočítat do tvaru potřebného pro získání polynomu


$$a = 2f(0) - 2f(1) + f'(0) + f'(1) \quad (5.47)$$

$$b = -3f(0) + 3f(1) - 2f'(0) - f'(1) \quad (5.48)$$

$$c = f'(0) \quad (5.49)$$


$$d = f(0) \quad (5.50)$$

Takto se dá spočítat kubická interpolace v oblasti mezi body $x = 0$ a $x = 1$. Obdobně lze interpolaci rozšířit pro více bodů. V případě počítání celého rozsahu osy z , byla použita Catmull-Rom splajn křivka popsaná ve zdroji [77], odvozená od popsané kubické interpolace. Tato splajn křivka je nejčastěji spojována se sledováním pohybu mezi snímky, při videosekvencích. Její výhoda spočívá ve využití počátečních podmínek získaných z první derivace předchozí křivky a tím přizpůsobení následující křivky tak, aby plynule navazovala. To znamená, že pro větší počet bodů lze dopočítat spline křivku tak, že plynule navazuje v celém rozsahu a tím se zpřesní odhad tvaru 3D modelu. Ukázka rozdílu mezi použitím kubické spline křivky, lineární interpolace a metody nejbližšího souseda je vidět na obr. 5.32.




Obr. 5.32: Porovnání interpolačních metod pro jednotlivé řezy

Přestože naměřeným datům nejvíce odpovídá výsledek metody nejbližší sused, reálnému uspořádání tkáně je značně vzdálený. Nejvíce reálnému vykreslení skutečného tvaru tkáně je výsledek získaný metodou kubické spline křivky.



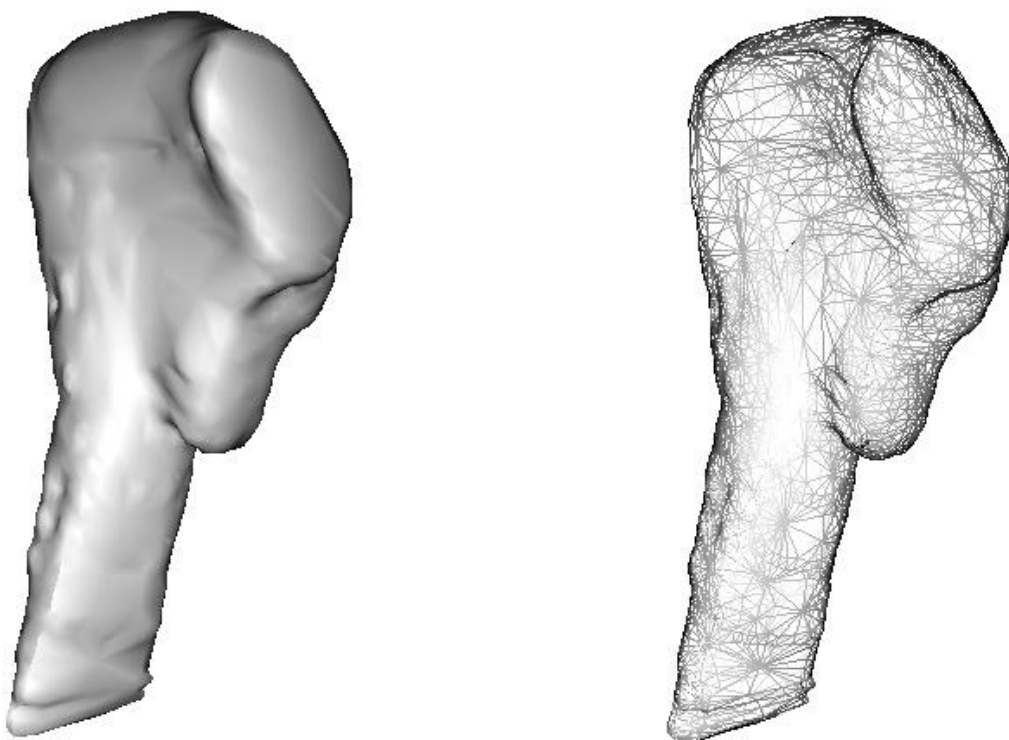
Obr. 5.33: Model kloubní hlavice při použití interpolovaných řezů metodou kubických splajnů

Na obr. 5.33 můžete vidět 3D model vytvořený metodou Marching Cubes, kde bylo využito interpolovaných řezů, tak aby bylo vyrovnáno rozlišení v ose z s osami x a y . Vytvořený model má vysoké rozlišení polygonů, což je vidět na drátovém modelu. Protože spousta navazujících polygonů má stejný směrový vektor jako jeho susedé, lze provést bezeztrátovou decimaci polygonů. Původní model na obr. 5.33 je složen z 5128 polygonů. Velikost rozmístění a tvar polygonů je vidět z drátového modelu. Při použití decimace tak, abychom zachovali původní tvar objektu, lze snížit počet polygonů na hodnotu odpovídající 2570 polygonům. To znamená, že výsledná komprese polygonů činí 50%, při minimální změně tvarových vlastností. To že při 50% decimaci dochází jen k malým a nevýznamným změnám je vidět i na naměřených datech na obr. 6.21.



Obr. 5.34: Model kloubní hlavice po decimaci polygonální sítě o 50%

S decimací je možné jít až na 35% původní polygonální sítě s tím, že zde už existují oblasti, které budou decimací značně zkresleny. Většinou se však jedná o nevýznamné části, které neovlivní celkové informace o tvaru objektu. Po provedení decimace je možné provést vyhlazení modelu, zde se využilo metody Laplacian+HC popsané ve zdroji [78], která omezuje snižování objemu modelu u metody Laplacian. Výsledek je vidět na obr. 5.35. Metoda Laplacian+HC pracuje v iteracích, kdy je v každé iteraci provedena operace vyhlazení pracující na principu hledání nových hraničních bodů sousedících polygonů. Čím více je provedeno iterací, tím více se hrany zaoblují a v nekonečnu by se limitně blížili kouli. To samozřejmě opět ovlivňuje tvarové vlastnosti objektu a je nutné omezit počet iterací na nutnou úroveň. Na obr. 5.35 je vidět model vyhlazený pomocí 5 iterací metody Laplacian+HC.



Obr. 5.35: Vyhlazený model kloubní hlavice pomocí metody Laplacian+HC

Aby bylo možné určit míru zkreslení, a tím i počet iterací případně míru decimace, je nutné stanovit objektivní metodu pro posuzování tvarových změn objektu. K tomuto účelu byla použita Hasdorffova vzdálenost, která je blíže popsána v kapitole 6.7. Právě z hlediska zachování vlastností jsou biomedicínská data velice citlivá. Zavedením této techniky můžeme velice dobře volit míru, s jakou jsou tvarové vlastnosti modelu měněny. Tato technika využívající měření rozdílu mezi původním modelem a jeho vyhlazenou, nebo decimovanou verzí je velice důležitá a zavádí nám novou metodiku pro objektivní posouzení těchto změn.

Tak jak byly popsány techniky na tvorbu 3D modelu kloubní hlavice jsou tyto techniky využity i na tvorbu 3D modelu disku a to tak, aby byla zachována vzájemná pozice těchto objektů.

6 Výsledky dizertační práce

6.1 Vstupní data

Algoritmy popsané v předchozí kapitole byly vyvíjeny na dvou typech dat. Pro měření bylo využito NMR zařízení značky Philips s typovým označením 9A12197 s indukcí magnetického pole o velikosti 1,5 T. Hlavní rozdíl mezi použitými typy sekvencí spočívá ve využití mikroskopické cívky, která umožňuje přiblížení oblasti čelistního kloubu bez ztráty odstupu od signálu. Díky použití mikroskopické cívky se zvětší rozlišení obrazu v osách x a y , což umožňuje přesnější rozlišení jednotlivých tkání čelistního kloubu. Parametry NMR zařízení s použitými typy cívek je vidět v tab. 6.1.

Tab. 6.1: Parametry NMR


Parametry	Bez mikroskopické cívky	S mikroskopickou cívkou
Indukce magnetického pole	1,5 T	1,5 T
Velikost viditelné oblasti v mm	150x150	70x70
Typ cívky	C3	Micro-47

První typ sekvence byla W-TSE PD, bez použití mikroskopické cívky. Tato sekvence snímá téměř celou oblast hlavy o rozměrech 150x150mm. Tato sekvence má nižší rozlišení a nižší odstup signálu od šumu. Nižší rozlišení způsobuje více problémů při segmentaci. Druhý typ sekvence má stejné parametry, tedy jedná se opět o W-TSE PD sekvenci, avšak je zde použita mikroskopická cívka Micro-47. Porovnání parametrů jednotlivých sekvencí je vidět v tab. 6.2.

Tab. 6.2: Porovnání parametrů sekvencí

Mikroskopická cívka	Rozlišení (pixel)	Pixel/mm	Typ sekvence	Šířka řezu (mm)
Ne	320x320	2,13x2,13	PDW-TSE	2
Ano	640x640	9,14x9,14	PDW-TSE	2

Když si uvědomíme, že použitím cívky se zlepšilo rozlišení pouze v osách x a y , ale v ose z zůstane stejné, je zřejmé, že budeme muset dopočítat v ose z větší počet řezů, abychom dosáhli stejného rozlišení jako je tomu u os x a y . To znamená, že použitím cívky sice zlepšíme rozlišení v osách x a y , ale o to více se nám v ose z na výsledném 3D modelu projeví šum a chyby segmentace. Příklady řezu obou sekvencí jsou vidět na obr. 6.1.



Obr. 6.1: Porovnání MR řezu bez použití mikroskopické cívký (vlevo) a s použitím mikroskopické cívký (vpravo)

6.2 Filtrace dat

Pro odstranění šumu ze vstupních dat bylo využito filtrace za pomoci vlnkové transformace, jejíž princip a vlastnosti jsou popsány v kapitole 3.2. Jedná se nejmodernější techniku filtrace šumu využívanou pro obrazy magnetické rezonance, jak lze vyčíst z [46],[47],[48] a [49]. Protože v práci [46] jsou použita podobná data, bylo možné využít použité techniky pro filtraci a bylo tedy možné využít poznatků o použitých typech mateřských vlnek (Haar, Daubechies, Coiflet), hloubky dekompozice a typu prahování waveletovy filtrace (měkké, hybridní a tvrdé). Pro vyhodnocení kvality filtrace jsme využili parametry kontrast, SNR a variace popsané v kapitole 3.2. Naměřené výsledky filtrace jsou vidět v tab. 6.3, kde jsou vyznačeny i nejvyšší dosažené hodnoty pro zvolené parametry. Nejdůležitějším parametrem je SNR, určující odstranění šumu a zlepšení homogenity tkání. SNR nejlépe vychází pro Haarovu vlnku pro měkké prahování, což koresponduje i s výsledky popsány v [46] a zároveň pro tuto vlnku vychází i nejvyšší hodnota variace. Z pohledu kontrastu, který byl měřen v oblasti hrany kloubní hlavice, nejlépe vychází Coiflet vlnka a to při použití prahu v hybridním režimu. Protože hlavním cílem filtrace bylo snížení šumu v obraze, který nejvíce ovlivňuje segmentační metody, jako nejlepší řešení se jeví filtr s Haarovou mateřskou vlnkou a měkkým prahováním v globálním režimu. Experimentálně byla zvolena hloubka dekompozice 4. Pro odhad prahu byla zvolena metoda univerzální prahové hodnoty definované podle vztahu (3.25), která měla v [46] nejlepší výsledky. Tato technika stanovení prahu byla otestována pro režimy:


Globální – Pro všechny detailní koeficienty je vypočten jeden práh.

Lokální – Pro každou skupinu detailních koeficientů je stanoven práh a každá tato skupina je prahována samostatně.


Tab. 6.3: Výsledky SNR pro vybrané parametry waveletové filtrace

Typ vlnky	Typ prahu	Typ prahování	SNR[dB]	Kontrast	Variace
Haar	Lokální	Měkké	24,14	0,53	0,61
		Hybridní	23,18	0,56	0,84
		Tvrdé	22,12	0,58	1,23
	Globální	Měkké	24,23	0,53	0,60
		Hybridní	23,28	0,56	0,82
		Tvrdé	22,16	0,58	1,22
Daubechy (2. řádu)	Lokální	Měkké	23,51	0,54	0,53
		Hybridní	22,43	0,56	0,76
		Tvrdé	21,58	0,58	1,03
	Globální	Měkké	23,60	0,54	0,51
		Hybridní	22,51	0,56	0,75
		Tvrdé	21,59	0,58	1,02
Coiflet (4. řádu)	Lokální	Měkké	22,22	0,62	0,70
		Hybridní	21,58	0,64	0,88
		Tvrdé	21,38	0,63	0,97
	Globální	Měkké	22,26	0,62	0,69
		Hybridní	21,60	0,64	0,88
		Tvrdé	21,38	0,63	0,97

Na obr. 6.2 je vidět graf porovnání SNR pro různé vlnky a různé typy prahování. Jak je vidět nejvyšší SNR zde má Haarova mateřská vlnka, která dosahuje hodnoty 24,23dB. Na dalším obrázku je vidět detail kloubní hlavice před a po filtraci. Můžeme zde vidět, že tkáň kloubní hlavice vykazuje více homogenní charakter, jak se dá od této tkáně očekávat. Díky waveletové filtraci je možné odstranit šum ze segmentované oblasti a zároveň zachovat její statistické a tvarové vlastnosti. Hlavně při segmentaci kloubního disku je důležité odstranit pouze šum a zachovat charakteristické statistické vlastnosti, které tuto tkáň odlišují od okolí. Výsledek vlnkové filtrace je vidět na obr. 6.3.



Obr. 6.2: Srovnání SNR podle použitých mateřských vlnek a typů prahování




Obr. 6.3: Detail kloubní hlavice před a po filtraci za pomoci vlnkové transformace

6.3 Ruční segmentace

Jako vstupní data byly použity snímky lidí různých věkových skupin a různého pohlaví. Vzhledem ke skutečnosti, že běžně se segmentace tkání čelistního kloubu neprovádí, neexistují tedy žádné veřejné i neveřejné databáze s touto tkání. Použitá vstupní data tak byla získána od pacientů radiologického oddělení Fakultní nemocnice Bohunice Brno. Aby bylo možné objektivně zhodnotit výsledky metody, je nutné je porovnat s co nejpřesnější možnou segmentací. Nejpřesnější segmentací je ruční označení od odborníků z oboru radiologie. Bohužel s ruční segmentací jsou spojena určitá úskalí. V první řadě se nejedná o běžnou činnost radiologů u tohoto typu tkáně. Běžná činnost radiologů u čelistního kloubu spočívá v určení diagnózy na základě rozboru 2D řezů z obrazů MRI, pomocí které se následně nasazuje léčba, ať už neinvazivní, nebo invazivní. To samozřejmě vede k tomu, že označování musí lékaři dělat nad rámec jejich běžné činnosti, která je navíc velice časově náročná. I přes velkou ochotu lékařů, nelze v krátké časové době získat velké množství dat, pokud se nebude provádět nějaká dlouhodobá studie čelistního kloubu, spočívající v označování této tkáně. Musíme si uvědomit, že u každého pacienta se jedná o data, kde je nutné projít a označit dva objekty ve 20 řezech. Bohužel při označování takto velkého množství dat dochází k únavě, která způsobuje nepřesnosti v segmentaci. Abychom předešli těmto nepřesnostem, byly data ručně segmentována celkově třikrát, kdy jednotlivá data pacientů byla odborníkům předkládána v náhodném pořadí. To zaručovalo, že stejná data nebyla segmentována ve stejném psychickém rozpoložení odborníka způsobeném únavou. Velkým problémem byl i nedostatek pacientů měřených pomocí mikroskopické cívky. Jak je vidět na vstupních datech zobrazených na obr. 6.1, tak data bez mikroskopické cívky mají tak malé rozlišení, že význam 3D modelů z takovýchto dat je příliš malý, na to aby byl pro radiology přínosem. To je hlavním důvodem, proč se tato práce také zabývala daty získanými pomocí mikroskopické cívky. Bohužel spolupracující pracoviště doposud nevládní mikroskopickou cívkou pro měření čelistního kloubu a pro experimentální účely ji měl zapůjčenu jen po krátkou dobu. Navíc NMR tomograf nemohl být použit pouze pro účely měření čelistního kloubu, když čekací doba pro pacienta je v řádu měsíců a tak bylo získáno jen omezené množství vstupních dat. Konkrétně se jednalo o 10 pacientů. Pokud je převedeme na počet obrazů, získali jsme databázi 200 obrazů se záznamy čelistního kloubu. Vezmeme-li v potaz nutný počet ručních segmentací na těchto datech, které museli radiologové provést pro 2 objekty a 3 nezávislé segmentace, jednalo se o projití a segmentaci v 1200 řezech. Pokud se brala daná činnost zodpovědně, tak doba potřebná pro segmentaci v jednom řezu zabrala v průměru 2-3 minuty, což činí celkově 40-60h, strávených nad ruční segmentací 10 pacientů. V případě, že by vytváření 3D modelů bylo prováděno na základě ruční segmentace, bylo by vysoce neefektivní z hlediska využití lidských zdrojů, což je jedna z hlavních motivací této práce. Bohužel tento neúměrný čas ruční segmentace, skutečnost, že se nejednalo o běžnou činnost radiologů v rámci jejich práce a krátkodobé zapůjčení mikroskopické cívky neumožnilo vytvořit dostatečně velkou databázi, aby bylo možné použít metody založené na strojovém učení. Tato práce se tedy zaměřuje na metody segmentace, které nejsou založeny na strojovém učení a zároveň by umožnily urychlit práci při vytváření 3D modelů čelistního kloubu. Pokud by se popsané algoritmy jednou staly součástí softwaru pro diagnózu nemocí čelistního kloubu, mohly by umožnit vytvořit větší databázi, kde by bylo možné metody založené na strojovém učení použít a zpřesnit tak výsledky, které jsou dále popsány v této kapitole.

Jak již bylo řečeno, jako standard pro objektivní srovnání metody byla použita ruční segmentace, která na stejném obraze byla prováděna celkem třikrát. To znamená, že z každého řezu získáme tři binární masky, které by za ideální situace měly být identické. Bohužel identické nejsou. Je to do velké míry způsobeno tím, že každý řez je řešen jako suma

informací k následujícímu řezu. Máme-li tedy řez tloušťky 1mm, tak výsledný obraz řezu magnetické rezonance je průměr dat v daném řezu. To do značné míry způsobuje, že objekt, který ručně segmentujeme, nemá pevné ohraničení, ale skládá se z přechodové oblasti mezi tkáněmi. Bohužel následně tedy není možné určit přesnou hranici objektu a dochází k odlišným ručním segmentacím totožného objektu. Lze však z toho vyvodit určité statistické vlastnosti, které poslouží pro objektivní zhodnocení vlastností navrženého algoritmu. Na obr. 6.4 je vidět neostrá hranice objektu, která se postupně propojuje s okolní tkání.



Obr. 6.4: Ukázka kondylu s neostrou hranicí

Při ruční segmentaci tkáně se jedná o vytváření Jordanovy křivky v prostoru \mathbf{R}^2 . Jordanova křivka je jednoduchá uzavřená rektifikovatelná křivka. Abychom ji mohli definovat na diskretním prostoru, kterým obraz je, musíme nejprve definovat relaci přilehlosti. Pokud budeme mít body $x, y \in M$, potom relace R na množině M se nazývá přilehlost, za podmínky, že R je ireflexivní a symetrická. Můžeme tedy říct, že body x a y jsou přilehlé, pokud bude platit xRy . Jednoduchou křivku lze potom definovat jako konečnou posloupnost různých bodů $p_0, p_1, \dots, p_n \in M$, za podmínky, že pro každou p_i , pro i z intervalu $\langle 1, n-1 \rangle$ lze nalézt právě dva přilehlé body p_{i-1}, p_{i+1} . Pokud pro p_i rozšíříme interval na tvar $\langle 0, n \rangle$ můžeme říci, že se jedná o jednoduchou uzavřenou křivku. Jordanova křivka nám tedy rozdělí množinu M na podmnožiny A a B tak, že musí platit

$$A \cup B = M, \quad (6.1)$$

$$A \cap B = \emptyset, \quad (6.2)$$

kde podmnožina A je tzv. Jordanova oblast a vymezuje nám tu část obrazu, kde se nachází segmentovaná tkáň. V obraze je potom Jordanova oblast označena logickou 1 a vnější oblast křivky reprezentovaná podmnožinou B logickou 0. Vznikne tak binární obraz s vyznačenou oblastí segmentované tkáně. Protože pro jednu tkáň v jednom řezu jsme ruční segmentací

získali tři odlišné binární masky, potom za správně segmentovanou tkáň můžeme považovat binární obraz vzniklý jako průměr těchto tří ručních segmentací. Průměr binární masky je počítán jako průměrná vzdálenost hrany binární masky od jejího těžiště pro úhly v rozmezí 0° – 360° . Lze to popsat rovnicí

$$l_\varphi = \frac{(\sum_{n=0}^k l_{\varphi n})}{k}, \quad (6.3)$$

kde φ je úhel natočení od těžiště a l je vzdálenost těžiště od hrany binární masky v úhlu φ . Na obr. 6.5 můžete vidět binární masky tří ručních segmentací totožného objektu a jejich průměrný obraz.



Obr. 6.5: Ukázka tří masek ručních segmentací a vpravo dole maska jejich průměru

Jak je na obrázcích vidět, opravdu se ruční segmentace mírně liší. Výsledný průměrný obraz zachycuje tvarové vlastnosti všech tří segmentací, jak je vidět například v horní části objektu, kde je zachycen výčnělek, který obsahují pouze dvě ze tří ručních segmentací.

6.4 Objektivní vyhodnocení segmentace

Protože se jedná o trojrozměrná data uložená ve voxelové reprezentaci, zvolili jsme pro porovnávání Sørensen–Dice koeficient popsáný v [79]. Tento koeficient byl zvolen na základě článků z oblasti volumetrie mozku, který používá podobný typ dat pro měření objemu mozku a na základě Sørensen–Dice koeficientu porovnává účinnost použitých metod, jak je popsáno v [80]. Jedná se tedy o obecně uznávaný koeficient pro porovnávání vícerozměrných segmentací. Sørensen–Dice koeficient vychází z rovnice:

$$QS = \frac{2C}{A+B} = \frac{2|A \cap B|}{|A|+|B|}, \quad (6.4)$$

kde A a B jsou v našem případě oblasti označené jako tkáň pro testovací a testovaný trojrozměrný binární obraz. QS může nabývat hodnot v rozmezí od 0 do 1, kdy hodnota 1 značí absolutní shodu. Sørensen–Dice koeficient v podstatě určuje procentuální shodu mezi dvěma objekty. Pokud těchto objektů máme více, můžeme vypočítat průměrnou hodnotu a směrodatnou odchylku.

Aby bylo možné určit nakolik je ruční segmentace přesná, byly porovnány jednotlivé ruční segmentace s jejich průměrem, který je považován za nejpřesnější možný výsledek. Hodnota přesnosti ručního označování lze spočítat pomocí rovnice

$$E[QS] = \int_{\Omega} QS \, dP, \quad (6.5)$$

a směrodatnou odchylku od této hodnoty lze definovat jako

$$\sigma = \sqrt{E[QS^2] - (E[QS])^2}. \quad (6.6)$$

Výsledek ruční segmentace pro kondyl lze pomocí rovnic (6.5) a (6.6) určit jako $0,93059842 \pm 0,02025517$. Lze tedy říci, že ruční segmentace kondylu dosahuje přibližně 93% účinnosti s odchylkou přibližně 2%. Kloubní disk má mnohem menší kontrast s okolím než je tomu u kondylu. Je tedy mnohem složitější správně určit jeho hranici a navíc má menší rozměry, než kondyl, proto se statisticky více projeví každá nepřesnost. Pro ruční segmentaci disku vycházejí hodnoty $QS = 0,826126 \pm 0,01956$. To znamená, že přesnost ruční segmentace dosahuje přibližně 83% úspěšnosti.

6.5 Výsledky současných metod a vyhodnocení segmentace kloubní hlavice

Jak již bylo několikrát zdůrazněno, z hlediska malého množství dat není možné použít algoritmy strojového učení. Musíme se tedy zaměřit na algoritmy, které nejsou založeny na statistických modelech získaných z vlastností získaných od učitele. Ze zdrojů jako je [81], který se jako jeden z mála zaměřuje na segmentaci v oblasti čelistního kloubu se vstupními daty z MRI je použita metoda založená na level-set funkci. Tato metoda byla poprvé publikována americkými matematiky Stanleyem Osherem a Jamesem Sethianem v [82]. Metoda se do dnešních dnů mnohokrát modifikovala a byla použita pro segmentaci převážně v oblasti biomedicínských dat včetně MRI, jak je popsáno například v [81], [83] a [84]. Algoritmus použitý pro otestování účinnosti této metody vychází z implementace popsané v [83], a lze ji označit jako relevantní reprezentace dosavadního stavu vědy v oblasti segmentace biomedicínských dat pomocí level-set funkce. Implementace algoritmu vychází z parciální diferenciální rovnice

$$\Phi(i) = \Delta T g(i) (W_a F_a |\nabla \Phi| + W_c F_c |\nabla \Phi|), \quad (6.7)$$

kde

$$g(I) = \frac{1}{1 + (\nabla I^* + g) \cdot 2}, \quad (6.8)$$

kde ∇I^* značí rozdíly s obrazem rozmazaným pomocí gaussovského rozostření. A ΔT lze definovat pomocí rovnice

$$\Delta T = \frac{1}{6 \cdot W_a \cdot W_c} \quad (6.9)$$

Protože se jedná o iterační algoritmus, značí i aktuální iteraci. Ve vzorci (6.7) máme tyto veličiny:


- W_a – Advekční váha
- F_a – Advekční síla
- W_c – Váha zakřivení
- F_c – Síla zakřivení

Advekční síla a váha určují ty vlastnosti křivky, které se vztahují k přitahování k hraně objektu. Váha a síla zakřivení mají souvislost s tvarovými deformacemi křivky v závislosti na hraně objektu v obraze. Protože se jedná pouze o algoritmus, se kterým je navržený algoritmus srovnáván, je jeho popis pouze obecný, podrobnější informace lze nalézt v [83]. Jak je v [83] podrobně popsáno, tak W_a a F_a se dají vyjádřit Advekčním koeficientem a podobně W_c a F_c se dají vyjádřit pomocí koeficientu zakřivení. Pro testování algoritmu bylo využito jeho implementace v prostředí ImageJ, která vychází z výše popsaných rovnic a rozšiřuje jeho vlastnosti o další parametry, jakými jsou koeficient rozpínání, koeficient zakřivení, advekční koeficient, koeficient rozptylu jasu a kritérium konvergence. Jak je vidět jedná se o celkem pět parametrů, které jednak ovlivňují rychlost segmentace a dále do značné míry i výsledek segmentace. Nejdůležitějším parametrem je kritérium konvergence, které udává, kdy dojde k zastavení iteračních cyklů. Aby bylo možné určit nejlepší možné řešení, které lze pomocí segmentačního algoritmu pomocí level set funkcí dosáhnout je nutné validovat hodnoty jednotlivých parametrů, dokud nedosáhneme globálního maxima. Právě příliš mnoho parametrů, které je nutné nastavit tak, aby algoritmus správně pracoval, patří mezi velké nevýhody této metody. Vzhledem k tomu, že výsledek je ovlivněn pěti parametry, je nutné hledat globální maximum v pěti-dimenzionálním prostoru. Navíc hranice parametrů nejsou pevně stanoveny, většinou však funkce limitně konverguje z jedné i druhé strany hodnotě, která souvisí s rozměry obrazu, kdy maximálně je označen celý obraz a minimálně je označena pouze inicializační funkce. Pro nalezení globálního maxima se nabízejí metody optimalizace založené na evolučních algoritmech. Tyto metody však nezaručují nejlepší řešení, tedy nalezení globálního maxima, ale může se jednat o jeho blízké okolí, nebo nějaké lokální maximum. Jediným jistým řešením je tedy validace hodnot všech funkcí. Pokud však vezmeme v úvahu, že se jedná o pět parametrů ve velkém rozsahu hodnot, dostáváme se potřebným výpočetním časem na stovky let. Naštěstí z principu jednotlivých parametrů

popsaného v [83], lze určit úzký rozsah hodnot, ve kterém se s vysokou pravděpodobností globální maximum nachází. Další pozitivní vlastností je nepřímá závislost čtyř parametrů. Do tohoto výčtu nepatří kritérium konvergence, které naopak závisí na ostatních čtyřech parametrech. Je tedy nutné vždy nalézt optimum vztahené ke kritériu konvergence.


V první fázi se jednalo o segmentaci kondylu, kde jako první parametr jsme validovali koeficient rozpínání. Na

obr. 6.6 je vidět graf funkce při validaci parametru rozpínání. Jak je vidět, tak hodnota koeficientu se nemění v celém měřeném rozsahu, tento parametr ovlivňuje pouze čas potřebný pro segmentaci, určuje totiž rychlost rozpínání křivky.




Obr. 6.6: Závislost Sørensen–Dice koeficientu na koeficientu rozpínání pro měřený kondyl

Druhým parametrem byl koeficient zakřivení, který udává vlastnost křivky měnit svůj tvar. Jak je vidět na obr. 6.7, tak parametr zakřivení dosahuje maxima hodnoty Sørensen–Dice koeficientu při hodnotě 2,6. Jak je vidět od hodnoty 0,5 do této hodnoty má graf vyšší strmost, než je tomu od hodnoty 2,6 dále, kde pozvolna klesá.




Obr. 6.7: Závislost Sørensen–Dice koeficientu na koeficientu zakřivení pro měřený kondyl



Obr. 6.8: Závislost Sørensen–Dice koeficientu na koeficientu zakřivení pro měřený kondyl

Obdobně je nalezeno maximum i u posledního parametru, jak je vidět na následujícím grafu, kde je koeficient rozptylu jasu i pro něj bylo nalezeno maximum a to v hodnotě 45.




Obr. 6.9: Graf validace hodnoty koeficientu rozptylu jasu pro kondyl

Jak je vidět z obr. 6.6 až obr. 6.9, že rozsah byl zvolen správně a že v daném rozsahu vždy existuje maximum Sørensen–Dice koeficientu. Hodnoty získaných parametrů pro segmentaci kondylu jsou vidět v tab. 6.4.

Tab. 6.4: Parametry pro segmentaci kondylu metodou s LevelSet funkcí


Parametr	Hodnota
koeficient zakřivení	2,6
advekční koeficient	3,9
koeficient rozptylu jasu	45
koeficient rozpínání	2
kriterium konvergence	0,0001

Jako poslední je hledána hodnota pro kritérium konvergence. Pokud známe hodnoty ostatních parametrů, potom je možné nalézt toto kritérium podobným způsobem, jakým jsme našli ostatní parametry a to validací hodnot ve zvoleném rozsahu. Na obr. 6.10 je vidět graf funkce. Na rozdíl od jednotlivých parametrů, je vidět, že konvergence je od leva rovnoměrná a pokles účinnosti algoritmu nastává až od hodnoty 0,0001. To je převážně dáno tím, že algoritmus konverguje okolo této hodnoty a nižších hodnot nedosáhne. Výsledná segmentace je zastavena po určitém počtu iterací, kdy konvergence nemění svoji hodnotu. Hodnota kritéria konvergence je tedy nastavena na krajní hodnotu 0,0001.



Obr. 6.10: Závislost Sørensen–Dice koeficientu na kritériu konvergence u segmentace kondylu.

Na obr. 6.11 je vidět průběh konvergence při segmentaci pomocí level set funkce. Jak je vidět ze začátku hodnota konvergence kolísá a od iterace 3500 postupně klesá, dokud nepřekročí hodnotu 0,0001. Iterační krok level set funkce dt je 0,0164.



Obr. 6.11: Průběh konvergence ke stanovenému kritériu algoritmu Level Set s nalezenými parametry pro kondyl


Jak je patrné ze všech grafů, které postupně zobrazují validaci jednotlivých parametrů algoritmu, založeném na level set funkci, maximální hodnota QS, které tento algoritmus dosahuje pro segmentaci kondylu je $78,5\% \pm 8,4\%$.

Při použití algoritmu popsaného v kapitole 5.1, který využívá modifikovanou metodu rozvodí, bylo dosaženo $QS = 87,7\% \pm 3,8\%$. V tab. 6.5 je porovnání všech popsaných metod, včetně ruční segmentace pro segmentaci kondylu.

Tab. 6.5: Tabulka Sørensen–Dice koeficientu pro kondyl


Metoda	QS
Ruční segmentace	$93,0\% \pm 2,0\%$
Level set	$78,5\% \pm 8,4\%$
Vlastní algoritmus založený na rozvodí	$87,7\% \pm 3,8\%$

Nový algoritmus založený na metodě rozvodí dosahuje $QS = 87,7\%$. Vezmeme-li v potaz, že ruční segmentace z hlediska statistiky dosahuje pouze $QS=93\%$, potom je to velice dobrý výsledek a to i z pohledu porovnání s metodou Level set, u které byla provedena validace parametrů, tak aby mohlo být dosaženo nejlepšího možného výsledku. Na obr. 6.12 je vidět porovnání výsledků použitých druhů segmentace zobrazených pomocí Jordanovy křivky. Na uvedených křivkách je vidět, že jsou si velice podobné a liší se pouze v detailech. Nepřesnosti segmentace se projeví právě v oblastech, kde dochází k neostrému přechodu jaký je vidět na obr. 6.4.



Obr. 6.12: Ukázka výsledků segmentace (zelená-ruční segmentace, červená – vlastní algoritmus, modrá – level set funkce)


Metoda Level set by mohla dosáhnout lepších výsledků, kdyby měla pro každý obraz samostatně nastaveny parametry. Automatickým nastavením parametrů metody Level set na základě vlastností aktuálního obrazu se dá získat velice dobrých výsledků, které by mohli předčít i nově navrženou metodu. Avšak princip, který byl zde použit pro nastavení parametrů, vyžaduje aktivní označení od odborníků, což naprosto potlačuje smysl následného použití této metody. Navíc je tento princip opravdu velice časově náročný. Statisticky se parametry pro jednoho pacienta počítají řádově kolem patnácti hodin. Nabízí tedy řešení, kdy se obrazy rozdělí do skupin podle jejich statistických vlastností, kdy se pro každou skupinu naleznou nejlepší parametry level set funkce a tím se dosáhne lepších vlastností. Toto řešení však opět vyžaduje velké množství dat, tak aby bylo možné vytvořit dostatečný počet reprezentativních prvků v každé skupině. Díky tomu by bylo možné odstranit chyby, jejíž příklad je vidět na obr. 6.13, kdy došlo k dosažení konvergence na hraně, která je způsobena šumem a není hranicí objektu.



Obr. 6.13: Ukázka rozdílu mezi ruční segmentací(zelená) a level-set funkcí(modrá) u kondylu

6.6 Vyhodnocení segmentace kloubního disku

Kondyl je tvrdou tkání, která má odlišné vlastnosti oproti měkké tkáni v jeho nejbližším okolí. To odpovídá kontrastu, který kondyl odděluje od okolní tkáně. U kloubního disku je tento kontrast mnohonásobně nižší a i s ruční segmentací je to mnohem složitější. Navíc je disk menší tkání, jak kondyl, tím se každý špatně identifikovaný voxel v koeficientu QS více projeví. Algoritmus navržený v této práci se snaží tento neblahý vliv minimalizovat. Na obrázku je vidět ruční segmentace od radiologa, který označil pomocí Jordanovy křivky oblast, kde se nachází kloubní disk. Je vidět, že kloubní disk má skutečně vlastnosti blízké okolní tkáni a jeho jasové hodnoty v obraze se od okolí příliš neliší, to způsobuje velké problémy nejen při automatických, ale i u ručních segmentací.




Obr. 6.14: Ukázka původního obrazu a ručně označené oblasti kloubního disku

Stejně jako u kondylu bude navržená metoda porovnána s metodou algoritmu Level Set. Protože se jedná o odlišný typ tkáně s jinými jasovými vlastnostmi oproti kondylu, je nutné opět nalézt optimální parametry metody založené na level-set. Hledání optimálních parametrů probíhá stejně jako u kondylu, tedy validací jednotlivých parametrů. Výsledek hledání parametrů pro kloubní disk za pomoci Level Set funkce je v tab. 6.6.

Tab. 6.6: Parametry pro segmentaci disku metodou s level-set funkcí

Parametr	Hodnota
koeficient zakřivení	2,11
advekční koeficient	4,02
koeficient rozptylu jasu	30
koeficient rozpínání	2
konvergence	0,001
QS = 61,3% ± 4,8%	

Průběh konvergence algoritmu při segmentaci s parametry v tab. 6.6 je vidět na obr. 6.15. Účinnost algoritmu, které dosahuje při parametrech v tab. 6.6 je 61,3% ± 4,8%.




Obr. 6.15: Průběh konvergence ke stanovenému kritériu algoritmu Level Set s nalezenými parametry pro kloubní disk

Metoda popsaná v kapitole 5.2 je oproti algoritmu s level set funkcí založena jednak na anatomických vlastnostech tkáně a dále na specifických statistických vlastnostech kloubního disku. Prvním krokem algoritmu je vymezení oblasti, kde se disk může pohybovat. Oblast vymezení této oblasti je vidět na obr. 6.16. Jak je popsáno v kapitolách 2.1 a 5.2 vychází se z anatomie čelistního kloubu a oblast zahrnuje všechny možné pozice (včetně různých disfunkcí oblasti s kloubním diskem), kde se může kloubní disk v závislosti ke kondylu nacházet. Samozřejmě vymezená oblast obsahuje velké množství redundance, která je následně odstraňována.



Obr. 6.16: Ukázka vymezené oblasti spočítaná algoritmem, kde se nachází kloubní disk

Další fází algoritmu je pravděpodobnostní model výskytu tkání s podobnými vlastnostmi přes všechny vrstvy, kde se kloubní disk nachází. Jak je popsáno v kapitole 5.2, vychází se z předpokladu, že tkáň kloubního disku na sebe v jednotlivých řezech navazuje, zatímco okolí je tvořeno úzkou tkání, případně mezerou, které neprotínou celý prostor všech řezů a tím se ve statistickém modelu projeví jako méně statisticky pravděpodobná oblast s kloubním diskem. Vypočtený pravděpodobnostní model pro řezy, do kterých patří i tkáň na obr. 6.16 je vidět na obr. 6.17, kde bílá oblast označuje nejpravděpodobnější oblast výskytu kloubního disku.




Obr. 6.17: Ukázka pravděpodobnostního modelu výskytu kloubního disku

Díky modelu nejpravděpodobnějšího výskytu kloubního disku je odstraněna největší část redundantní tkáně a zmenší se prostor, ve kterém se hledá kloubní disk. Pro přesné určení kloubního disku v každé vrstvě je použit genetický algoritmus, který modeluje histogram tvořený dvěma objekty s vlastnostmi blízkými gaussovu rozložení pravděpodobnosti s různými parametry. Lze tím definovat jasové vlastnosti pro objekt kloubního disku a na základě těchto vlastností oddělit kloubní disk od okolní tkáně. Algoritmus byl stejně jako Level set metoda porovnáván s průměrnou ruční segmentací. Výsledná QS u této metody dosáhla $71,5\% \pm 3,2\%$. V tab. 6.7 je porovnání ruční segmentace s level-set funkcí a s novou metodou využívající anatomického uložení disku.

Tab. 6.7: Sørensen–Dice koeficienty pro kloubní disk

Metoda	QS
Ruční segmentace	$82,6\% \pm 2,0\%$
Level set	$61,3\% \pm 4,8\%$
Nový algoritmus	$71,5\% \pm 3,2\%$

Jak je vidět v tabulce, tak účinnost segmentace kloubního disku je nižší, než je tomu u kondylu. Odpovídá to vlastnostem kloubního disku a jeho okolí, což se projevilo už v ruční segmentaci, která se od průměru liší o 17,4%. Výsledná 71,5% účinnost u nového algoritmu není vysoká, ale v porovnání s 61,3% účinností dosažené při použití metody level-set je to významný úspěch, který umožňuje urychlit práci doktorům. Musíme vzít v potaz i skutečnost, že se jedná o průměrnou hodnotu všech porovnávaných tkání, což znamená, že některé tkáně mohou dosahovat vyšších hodnot účinnosti a nebudou vyžadovat tak velký zásah od lékařů. Algoritmus je navržen jako poloautomatický, aby bylo zaručeno, že výsledek bude odpovídat více hodnotě ruční segmentace. Algoritmus tedy umožní urychlit práci odborníků při ruční segmentaci tak, aby nebylo nutné provádět segmentace pro každý obraz zvlášť, ale aby se jejich práce omezila pouze na opravy chyb u automatické segmentace. Na obr. 6.18 je vidět rozdíl mezi ruční segmentací a automatickou segmentací pomocí navrženého algoritmu. Rozdíl se projevil pouze v malé části obrazu a je dobře vidět, že 28,5% u takto malého objektu tvoří opravdu jen velmi malou oblast, jejíž oprava zabere mnohem méně času, než je tomu u ruční segmentace celého objektu.




Obr. 6.18: Porovnání průměrné ruční segmentace kloubního disku s navrženou metodou

6.7 Nadvzorkování dat a tvorba 3D modelu


Další fází zpracování dat je nadvzorkování v ose z . Mikroskopická cívka dokáže zvýšit rozlišení v osách x a y , ale nedokáže to v ose z , kde zůstává původní rozlišení. Podvzorkovat osy x a y by znamenalo ztratit informace, které jsme získaly pomocí mikroskopické cívky. Princip vzorkování využívá kubického splinu. Na obr. 6.19 je vidět výsledek nadvzorkování s koeficientem nadvzorkování $N = 16,66$. Jak je vidět mezi prvním a posledním vzorkem, které reprezentují původní vzorky získané segmentací, je mezi nimi 16 nově vypočtených vzorků. Nové vzorky dodržují tvarovou kontinuitu, která vede hranami jednotlivých vrstev. Podle principu použité kubické interpolace, nezávisí výpočet nových vzorků pouze na původních krajních vzorcích, jako je tomu u lineární interpolace, ale je závislá i na tvaru předchozích a následujících vzorků. Tento princip umožňuje přizpůsobit se tvarovým vlastnostem kloubního disku a díky tomu se daří dokreslit správné uložení disku včetně jeho napojení na okolní tkáň. Na obrázku je dále vidět, že změna jednotlivých vzorků je

minimální. Podobně jako jsme pomocí QS měřili podobnost segmentačních metod, můžeme využít tuto metodiku pro měření změny mezi vzorky. Průměrná naměřená změna mezi vzorky činí 2,6%. Je tedy vidět, že mezi vzorky je jen velice malá změna, na které lze pozorovat hladký průběh změny na hraně objektu.



Obr. 6.19: Ukázka vypočtených vzorků vzniklých nadvzorkováním mezi dvěma původními vzorky

Díky nadvzorkování získáme dostatečně přesná data pro vytvoření 3D modelu. Výsledkem nadvzorkování je zvýšení přesnosti voxelu. Získali jsme tak velice přesný voxelový model. Dalším krokem je přepočítání tohoto modelu z voxelové podoby do podoby polygonální, která více odpovídá reálnému světu. Výhoda polygonálních modelů spočívá v možnosti jejich tisku na 3D tiskárnách a prohlížení v různých softwarech včetně využití rozvíjející se moderní technologie rozšířené reality. Pro převod do polygonálního modelu bylo využito metody nazývané jako pohybuje se kostka (Marching Cubes). Tato metoda se stala standardem pro převod do polygonálního modelu. Podrobnosti k této metodě jsou popsány v kapitole 5.3. Protože metoda pohybuje se kostky je velice používanou metodou, existuje mnoho jejích řešení v podobě knihoven a softwaru. Pro konkrétní převod kondylu a kloubního disku do podoby polygonálního modelu byla využita knihovna Java3D a její rozšíření v podobě ij3D. Použitá metoda používá pouze jeden parametr, kterým je velikost kostky v poměru k voxelu.



Obr. 6.20: Ukázka změny velikosti kostky a tím rozlišení u metody pohybující se kostka (Marching Cubes)

Na obr. 6.20 je vidět, že pokud chceme dosáhnout největší přesnosti, musí být zvolená kostka velikosti 1:1 s voxelu původního modelu. Při vytváření však vznikne velké množství polygonů, ze kterých je objekt tvořen. U modelu kondylu se pohybuje počet polygonů kolem čísla 85 000. Takto velký model způsobuje problémy při rychlosti zobrazování a to i ve výkonných stanicích na platformě x86. Protože však i homogenní plochy jsou tvořeny velkým počtem polygonů, je možné snížit počet těchto polygonů, aniž by došlo k významnému snížení přesnosti modelu. Proces snižování polygonů u polygonálního modelu se označuje jako decimace. Abychom byli schopni určit, nakolik se změnil tvar objektu, je nutné zavést systém jejich porovnávání. Abychom byli schopni určit, v jakých částech změny proběhly a jakého byli charakteru, nelze modely porovnat jen na základě jejich objemu. Je tedy nutné zavést měřitelnou jednotku, která by určila podobnost v jednotlivých oblastech modelu. Obecně uznávanou metodikou pro porovnávání polygonálních modelů je Hausdorffova vzdálenost jak je popsáno ve zdrojích [85],[86] a [87]. Vyjdeme-li ze dvou neprázdných podmnožin X a Y metrického prostoru (M,d) , potom můžeme Hausdorffovu vzdálenost $d_H(X,Y)$ definovat jako

$$d_H(X,Y) = \max\{\sup_{x \in X} \inf_{y \in Y} d(x,y), \sup_{y \in Y} \inf_{x \in X} d(x,y)\}, \quad (6.10)$$

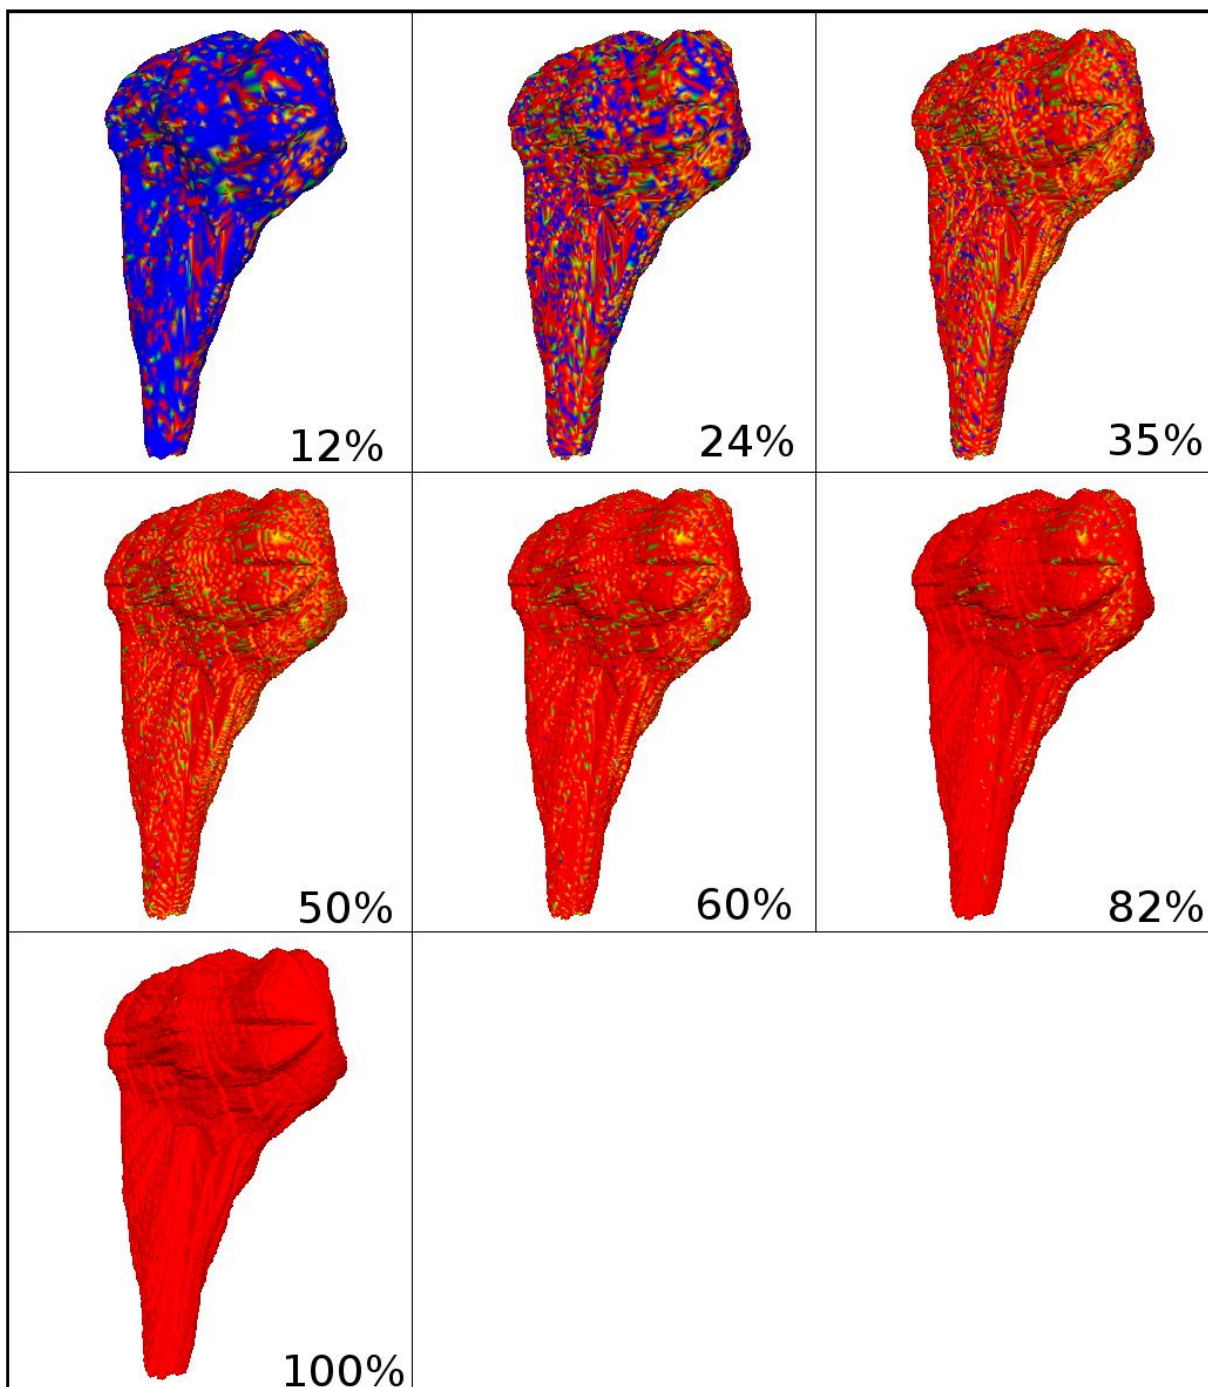
kde *sup* reprezentuje supremum a *inf* označuje infimum [85].

Po zvedení metriky v podobě Hausdorffovy vzdálenosti pro porovnávání modelů lze vypočítávat odchylky modelu přímo v daném bodě polygonální sítě. Protože při decimaci dochází k změně velikosti polygonální sítě nelze porovnávat objekty na základě jednotlivých polygonů, ale je nutné vypočítávat vzdálenost na základě vzorkování s určitým počtem vzorků, který je vyšší, než je počet polygonů u nedecimovaného objektu. V případě kondylu má nezdecimovaný model okolo 85000 polygonů a pro měření Hausdorffovy vzdálenosti bylo použito 1 000 000 vzorků. Vzorkování je naddimenzované, ale je tím zaručena vysoká přesnost při měření mezi oběma polygonálními sítěmi. Díky měření rozdílů mezi modely lze určit optimální míra decimace v závislosti na změně tvaru modelu a lze přesně určit, ve kterých částech tohoto modelu dojde ke změnám a o jak velké změny se jedná. Jak ukazuje obr. 6.21, kde je vidět barevné rozlišení Hausdorffovy vzdálenosti v jednotlivých místech modelu kondylu od původního modelu, kde je vzdálenost ve všech místech nulová, až po model který je decimován až na hodnotu 12% polygonů původního modelu kondylu. Barevné označení určuje velikost Hausdorffovy vzdálenosti, kde nulová změna je označena červeně, malá změna žlutě, střední změna zeleně a velká změna je označena modře. Z obrázku je patrné, že optimum pro decimaci se pohybuje někde okolo 30%, kde velkou změnu obsahují jen nejjemnější detaily, které nemají relevantní význam pro určení diagnózy. Při použití v mobilních zařízeních, které obecně nemají velký výpočetní výkon, na který má významný vliv právě počet polygonů objektu lze jít až na hranici 20% počtu polygonů oproti původnímu modelu. Stejně tak je decimace možná až na hranici 20% počtu polygonů původního modelu v případech určených pro 3D tisk, kde se rozlišení tiskárny pohybuje v hodnotách 0,1mm, což je hluboko pod hranicí chyb způsobených decimací.

Tab. 6.8: Tabulka naměřených hodnot d_H pro různé hloubky decimace

Decimace v %	Maximální d_H [-]	Průměrná d_H [-]	RMS d_H [-]
12	0,004121	0,000498	0,000684
24	0,002625	0,000221	0,000339
35	0,001472	0,000099	0,000179
50	0,001386	0,000034	0,000084
60	0,001409	0,000011	0,000045
82	0,000288	0,000001	0,000001


V tab. 6.8 jsou vidět výsledky Hausdorffovy vzdálenosti vypočtené pro modely s různou hloubkou decimace. V tabulce není uvedena minimální naměřená hodnota Hausdorffovy vzdálenosti, protože je pro všechny decimované modely rovna hodnotě 0. Je to dáno tím, že vždy existuje polygon, který odpovídá totožnému polygonu v původním modelu. Jak je vidět na obr. 6.21, tak skutečně i při vysoké decimaci kdy decimovaný model obsahuje jen 12% z původního počtu polygonů, existují oblasti, které jsou totožné s původním modelem (vyjádřeno červenou barvou).



Obr. 6.21: Ukázka decimovaného modelu kondylu s barevným rozlišením Hausdorffovy vzdálenosti (procenta určují poměr počtu polygonů k jejich počtu u původního modelu)


Posledním krokem při vytváření 3D modelu je jeho vyhlazení. Přestože se podařilo pomocí interpolace dopočítat tvary mezi řezy, vždy se bude jednat o digitální signál, který bude trpět podobnými chybami jako je kvantizační chyba u 1D a 2D signálů. V podstatě se jedná o ostré přechody mezi jednotlivými řezy. Tyto přechody jsou zapříčiněny metodou pohybující se kostky, kdy tvary kostky jsou předem určeny tabulkou a neodpovídají přímo stavu v řezech a jsou přizpůsobovány prostoru mezi dvěma řezy, avšak ne v širších souvislostech s řezy okolními. Pro odstranění těchto nepřesností se standardně používá vyhlazovací metoda, jak bylo popsáno v kapitole 5.3, v práci byla využita metoda Laplacian HC. Protože u vyhlazování vždy dochází k deformaci objektu, lze míru vyhlazení určovat

právě na základě míry zkreslení modelu. Při vyhlazování objektu se jedná vždy o kompromis mezi úrovní vyhlazení a potlačení tak nedostatků způsobených převodem z voxelové podoby do polygonální a mírou zkreslení způsobenou změnou tvarových vlastností modelu bez přesných znalostí skutečného tvaru objektu. Podobně jak je to u měření podobnosti objektů u decimace i zde je nutné zavést metriku pomocí Hasdorffovy vzdálenosti. V případě vyhlazování pomocí metody Laplacian HC totiž nelze použít metodu založenou na počítání objemu objektu. Metoda Laplacian HC je rozšířením metody Laplacian o redukci snižování objemu modelu. Proces vyhlazování je iteračním procesem, kdy každou iterací jsou hrany objektu více vyhlazeny. Proces vyhlazování spočívá ve výpočtu nové hrany na základě hran v jejím bezprostředním okolí, při kterém dochází k zmenšování objektu směrem k jeho těžišti. Metoda HC rovnoměrně zvětšuje objekt tak, aby jeho objem co nejvíce odpovídal objemu původního objektu. Vlivem této vlastnosti by porovnávání objektů na základě jejich objemu vnášelo do měření neúměrně vysoké zkreslení, zatímco při porovnávání na základě Hausdorffovy vzdálenosti, kdy jsou porovnávány skutečné odchylky mezi polygonálními sítěmi, k tomuto zkreslení nedochází. Na obr. 6.22 jsou vidět změny při jednotlivých iteracích metody Laplacian HC na modelu kondylu, kde první obrázek ukazuje vstupní model s decimací na 35% původního modelu. Protože se změny nejvíce projevují u malých detailů modelu, je změna nejvíce znatelná u prvních 5 iterací. Ve skutečnosti se změna děje i v dalších částech modelu, kde se projevuje v širších oblastech, ale v menších změnách.




Obr. 6.22: Ukázka vlivu metody Laplacian HC 0 až 7 iterací

Protože změny ve vyšších iteracích nejsou na obrázcích znatelné je lepší opět kondyl obarvit podle míry Hausdorfovy vzdálenosti. Na obr. 6.23 je vidět Hausdorfova vzdálenost od vstupního modelu, který je v levém horním rohu.




Obr. 6.23: Ukázka vlivu metody Laplacian HC pomocí barevného vykreslení d_H pro iterace 0 až 8

Pro porovnání je vidět i na obr. 6.23 vývoj Hausdorffovy vzdálenosti na počtu iterací metody Laplacian HC. Graf zobrazuje průběh maximální, průměrné a RMS hodnoty Hausdorffovy vzdálenosti. Průměrná a RMS hodnota rostou pomalejším tempem jako je tomu u maximální hodnoty, což odpovídá vlastnostem vyhlazování, kdy se nejvíce mění ostré hrany objektu, které nejvíce ovlivňují d_H . Musíme si však uvědomit, že ve výsledku je nejvíce vypovídající právě maximální hodnota, která určuje jaká je největší možná odchylka objektu od vstupního modelu. Musíme si uvědomit, že vyhlazovací algoritmus působí jako dolnoproputný filtr ve trojrozměrném prostoru, to znamená, že potlačuje vysokofrekvenční složky v oblasti polygonálního modelu. Podobně jako u 2D obrazové funkce i zde se přenáší nejvíce informace pomocí nízkých frekvencí a vysoké frekvence poskytují informace o detailech. Tyto detaily však poskytují informace o tvarových vlastnostech v lokální oblasti polygonální sítě. Například u kloubního disku (na obr. 6.25) tyto lokální maxima zobrazují místa, kde se kloubní disk napojuje na okolní tkáň, což může být cenná informace pro stanovení diagnózy. Nelze tedy tyto vysokofrekvenční složky potlačit do tak vysoké míry, aby ovlivňovaly důležité informace o 3D modelu.



Obr. 6.24: Ukázka vývoje d_H pro iterace metody Laplacian HC

Pro vytvoření 3D modelu byla na základě objektivních metod nastavena decimace na 30% původního počtu a zároveň vyhlazovací algoritmus Laplacian HC byl použit po 5 iteracích. Toto nastavení bylo zvoleno proto, abychom dosáhli nejlepšího kompromisu mezi ztrátou informace způsobenou zkreslením a kvalitou a jednoduchostí modelu, který by byl použitelný pro široké spektrum zařízení, včetně mobilních zařízení s nízkým výpočetním výkonem. Ukázka výsledného modelu čelistního kloubu tvořeného kondylem a kloubním diskem je vidět na obr. 6.25.



Obr. 6.25: Ukázka výsledného 3D modelu při otáčení v ose y vždy posunutě o 40°

6.8 3D tisk

Model na obr. 6.26 byl rozšířen o ručně segmentovaný výřez kloubní jamky a byl vytištěn na 3D tiskárně ZPrinter 650 s parametry uvedenými v tab. 6.9.

Tab. 6.9: Parametry 3D tiskárny

Parametr	hodnota
Barva	390000 barev
Rozlišení	600x540 dpi
Minimální tisknutelná oblast	0.1mm

Na obr. 6.26 je vidět výsledek vytištěného 3D modelu čelistního kloubu. Bílé části označují tvrdé tkáně, kterými jsou kondyl a kloubní jamka a červená část je měkká tkáň kloubního disku, která je nejdůležitější částí čelistního kloubu. Jak je vidět ze 3D modelu jedná se o dislokaci disku v anterior směru. Tato dislokace disku je samozřejmě viditelná i u 2D řezů a zkušený radiolog dokáže určit diagnózu, ale pro předoperační přípravu je důležité znát i velikost kondylu, tvar a velikost kloubního disku a jejich vzájemná poloha v prostoru, což nelze snadno z 2D snímků vyčíst.



Obr. 6.26: Model čelistního kloubu vytištěný pomocí 3D tiskárny ZPrinter 650

7 Závěr

Práce se zabývá oblastí segmentace a tvorbou 3D modelu čelistního kloubu. Jedná se o nejčastěji používaný kloub v lidském těle. Právě složitost a vytíženost kloubu způsobuje značné problémy velké části populace, aniž by si to kolikrát konkrétní lidé uvědomovali, protože projevy nemusí zdánlivě s čelistním kloubem souviset. Problémy s čelistním kloubem postihuje podle studie [9] 33% populace a lze je zařadit mezi civilizační choroby. Právě proto se mnoho současných odborných týmů z oblasti čelistní chirurgie zabývá nemocemi čelistního kloubu, jak je popsáno v odborných pracích [88]-[97]. Z lékařského hlediska se tedy jedná o aktuální problematiku, která je řešena v mnoha různých týmech po celém světě. Čelistní kloub je tvořen třemi částmi, ale pro diagnostiku je nejdůležitější vzájemná pozice mezi kloubní hlavici a kloubním diskem. Současný stav diagnostiky je založen na zkušenosti odborníků z oboru radiologie, kteří na základě 2D snímků MRI porovnávají vzájemnou polohu kloubní hlavice a kloubního disku a do protokolu pro čelistního chirurga slovně popisují tuto vzájemnou pozici a případnou diagnózu. V oblasti zlomenin čelisti a čelistního kloubu se sice rekonstrukce 3D modelu používá, ale jedná se o rekonstrukci z dat CT, na kterých není kloubní disk viditelný. To samozřejmě znemožňuje použití v případech disfunkce kloubu způsobené kloubním diskem, který je vidět pouze ve snímcích magnetické rezonance. Získávání dat z magnetické rezonance je velice zdlouhavý a drahý proces, který klade velké nároky na pacienta. Díky použití magnetické rezonance je kromě tvaru tkáně v datech obsažena i jejich prostorová informace. Zatímco zjišťování stavu na základě 2D snímků tuto informaci nevyužívá, při tvorbě 3D modelu můžeme tuto informaci zužítkovat a rozšířit tak informace, které mohou posloužit pro zlepšení diagnózy a předoperační přípravy. Využití stávajících MRI dat umožňuje zachovat všechny stávající procesy v práci s pacientem. Rozšiřuje se tak pouze oblast zpracování získaných dat, kde se snaží o efektivnější reprezentaci polohy a tvaru tkání. Proces rekonstrukce 3D modelu čelistního kloubu se skládá z několika procesů, v první řadě se jedná o filtraci a segmentaci tkání z 2D snímků MRI, další fází je nadzorkování dat a převod do polygonálního modelu. Poslední fáze vylepšuje vlastnosti rekonstruovaného modelu, jakými jsou snížení počtu polygonů v síti (decimace) a vyhlazení modelu, tak aby více odpovídal tvaru reálné tkáně.

V práci byly navrženy a otestovány techniky pro segmentaci kloubní hlavice a kloubního disku s možností ruční korektury se zachováním informace o jejich vzájemné poloze. Tyto algoritmy vycházejí ze znalosti anatomie čelistního kloubu a rozboru různých možných poloh disku včetně poloh při nemocech a disfunkcích čelistního kloubu. Dále se využívá vlastností navazování tkání v jednotlivých řezech a jejich vzájemné polohy a statistických jasových vlastností. Pro analýzu a zpracování statistických vlastností bylo využito genetického algoritmu, který umožňuje v relativně krátké době nalézt dostatečně přesné řešení pro analýzu histogramu tkání. Ruční korekturou je myšleno to, že přestože segmentace probíhá automaticky bez nutnosti vnější intervence, výsledky segmentace jsou vždy kontrolovány radiologem a případně upravovány. Tento princip je přizpůsoben lékařskému prostředí, kdy odpovědnost za správnou diagnózu a lékařské rozhodnutí spočívá na bedrech odborného lékaře. Nelze tedy plně automatizovat celý systém segmentace a tvorby 3D modelu do té míry, aby nemohl být z vnějšku ovlivněn během samotného procesu a zároveň aby za výsledek mohl ručit odborný lékař, jak to praxe vyžaduje. Aby bylo možné určit účinnost algoritmu segmentace (bez vnější intervence), byl vytvořen soubor dat označený za pomoci vícenásobné ruční segmentace, ze které byl vypočítán průměr. Pro vyhodnocování účinnosti algoritmu pro 3D data byl zvolen Sørensen–Dice koeficient, který je obecně uznávaný pro porovnávání 3D modelů lidských tkání. Vzhledem k tomu, že ruční segmentace byla vícenásobná, mohla být statisticky zhodnocena. Pro oblast kloubní hlavice vychází účinnost

ruční segmentace $93\% \pm 2\%$ a pro kloubní disk $82,6\% \pm 2\%$. Z oblasti segmentace a zpracování biomedicínských dat popsaných v [98]-[100] vyplývá, že největší progresi v posledních letech zažívají metody založené na level-set funkci a dokonce v [81] byla tato technika využita i pro segmentaci disku čelistního kloubu z MRI dat, kde měla dobré výsledky. Technika segmentace biomedicínských dat pomocí level set funkce popsaná v [83] byla vybrána jako relevantní reprezentace výzkumu v této oblasti a jako taková byla porovnána s algoritmy popsanými v této práci. Algoritmus aktivních kontur má velké množství parametrů, které zásadně ovlivňují výsledek segmentace, proto byly tyto parametry validovány tak, aby bylo možné nalézt nejlepší řešení. Výsledek segmentace kloubní hlavice pomocí aktivní kontury využívající Level-set funkci popsaný pomocí Sørensen–Dice koeficientu je $78,5\% \pm 8,4\%$ u kloubní hlavice a $61,3\% \pm 4,8\%$ u kloubního disku. Námi navržená metoda dosahuje hodnoty $87,7\% \pm 3,8\%$ u kloubní hlavice a $71,5\% \pm 3,2\%$ kloubního disku a to s významnou časovou úsporou. Následně po segmentaci tkání je vytvářen polygonální model. Pro tvorbu modelu byly použity standardní techniky jako Marching Cubes a pro vyhlazování byla využita metoda Laplacian+HC umožňující zachování minimálně 98% objemu modelu. Protože metoda Laplacian+HC je iterační metodou, bylo nutné vyřešit počet iterací, při kterých ještě nedojde k příliš velkému zkreslení modelu. K objektivnímu zhodnocení modelu bylo využito metody Hausdorffovy vzdálenosti, pomocí které je možné porovnávat polygonální mapy. Aby bylo možné použít segmentovaná data pro tvorbu polygonálního modelu, musely být data nadzorkována v ose z. Zde byl navržen algoritmus nadzorkování tkáně pomocí kubického splajnu tak, aby byla co nejvíce zachována její tvarová kontinuita. Výsledkem byl realistický 3D model kloubní hlavice a disku s významnými detaily, které nebylo možné v 2D oblasti vůbec zaznamenat.

Hlavní přínos práce spočívá v nových technikách, které přinesou více informací pro stanovování diagnózy v oblasti čelistního kloubu a umožní tak zlepšit předoperační přípravu. Hlavně v oblasti segmentace kloubní hlavice a kloubního disku z dat MRI bylo dosaženo dobrých výsledků, které s přibývajícím množstvím takto označených dat mohou dále přispět k vytvoření větších databází čelistního kloubu a s tím souvisejícím využitím metod strojového učení. Tyto databáze mohou dále zpřesnit metody segmentace a na ně navazující polygonální modely. Zavedení metod do praxe a využití rozvíjejícího odvětví 3D tisku může pomoci při předoperačních přípravách čelistních chirurgů, kteří tak s větší přesností budou moci provádět invazivní zásahy v oblasti kloubu a urychlí se tak doba rekonvalescence po těchto zákrocích. Více detailů a informací získaných z 3D modelů mohou napomoci k odhalení různých deformací, které nejsou v 2D zobrazení vůbec zaznamenatelná a umožní tak nasadit včasnou léčbu, což by mohlo pomoci předejít různým komplikacím. U získaných modelů je například možné identifikovat místa, kde se kloubní disk propojuje s okolními vazy. Tyto modely byly konzultovány s čelistními chirurgy, kteří potvrdili jejich podobu se skutečnou tkání čelistního kloubu.

Uvedené metody a aplikace byly navrženy při řešení projektu Grantové agentury české republiky GAČR 102/12/1104 a projektu KONTAKT ME10123 a dále ve spolupráci s Fakultní nemocnicí Brno. Některé části byly navrženy ve spolupráci se zahraničními instituty Universitat Politècnica de Catalunya a Hospital de Mataró a University of Southern California. Výsledky práce byly publikovány na mezinárodních konferencích jako např. Sixth International Conference on Contemporary Computing, International Conference on Telecommunications And Signal Processing a v odborných a vědeckých impaktovaných časopisech jako Measurement Science Review a International Journal Of Colorectal Disease.

Seznam použité literatury

- [1] Stevenson G. J., Comparison of Several Noninvasive Methods for Estimation of Pulmonary Artery Pressure, *Journal of the American Society of Echocardiography*, Volume 2, Issue 3, May–June 1989, Pages 157-171, ISSN 0894-7317
- [2] Avcu S, Koseoglu M N, Ceylan K, Dbulutand M, Unal O. (2011) The value of diffusion-weighted MRI in the diagnosis of malignant and benign urinary bladder lesions. *The British Journal of Radiology* 84:1006, 875-882.
- [3] Athina C Tsili, Maria I Argyropoulou, Dimitrios Giannakis, Stavros Tsampalas, Nikolaos Sofikitis, Konstantinos Tsampoulas. (2012) Diffusion-weighted MR imaging of normal and abnormal scrotum: preliminary results. *Asian Journal of Andrology* 14, 649-654
- [4] Nardotto, Sonia a Silvana G. Dellepiane. An Automatic Segmentation Method for MRI Multiparametric Volumes: from quantitative measurement to in-vivo neuroanatomy. *International Journal of Computer Theory and Engineering*. 2014, vol. 6, issue 2, s. 75-80. DOI: 10.7763/ijcte.2014.v6.840.
- [5] Weisenfeld, Neil I., Simon K. Warfield, Andrew M. Taylor, Jan Bogaert, Stéphanie Bricq, Christophe Collet, Jean-Paul Armspach, A. M. Taylor A J. Bogaert. Automatic segmentation of newborn brain MRI: from quantitative measurement to in-vivo neuroanatomy. *NeuroImage*. 2009, vol. 47, issue 2, s. 93-107. DOI: 10.1007/174_2011_333.
- [6] Leonardi, Valentin, Vincent Vidal, Marc Daniel, Jean-Luc Mari, Stéphanie Bricq, Christophe Collet, Jean-Paul Armspach, A. M. Taylor A J. Bogaert. Multiple reconstruction and dynamic modeling of 3D digital objects using a morphing approach: from quantitative measurement to in-vivo neuroanatomy. *The Visual Computer*. 2014, vol. 47, issue 2, s. 93-107. DOI: 10.1007/s00371-014-0978-6.
- [7] Englert, Fred, Vincent Vidal, Marc Daniel, Jean-Luc Mari, Stéphanie Bricq, Christophe Collet, Jean-Paul Armspach, A. M. Taylor A J. Bogaert. Automatische Segmentation von Sprachsignalen: from quantitative measurement to in-vivo neuroanatomy. *The Visual Computer*. 2014, vol. 47, issue 2, s. 93-107. DOI: 10.1007/s00371-014-0978-6.
- [8] McNeill C. History and evolution of TMD concepts . *Oral Surg Oral Med Oral Pathol Oral Radiol Endod* 1997; 83: 51 – 60.
- [9] American Academy of Orofacial Pain, de Leeuw R (ed). *Orofacial Pain: Guidelines for Assessment, Diagnosis and Management*, 4th ed., Chicago: Quintessence, 2008: 131– 133, 158.
- [10] Okeson JP. *Management of Temporomandibular Disorders and Occlusion*, 6th ed. St. Louis: CV Mosby, 2008: 133.
- [11] Tomas X.; Pomes J.; Berenguer J. MR Imaging of Temporomandibular Joint Dysfunction. *RadioGraphics*[online]. 2006, 1, [cit. 2010-04-27]. Dostupný z WWW: <<http://radiographics.rsna.org/content/26/3/765.full>>.
- [12] Rammelsberg P, Pospiech PR, Jager L, Pho Duc JM, Bohm AO, Gernet W. Variability of disk position in asymptomatic volunteers and patients with internal derangements of the TMJ. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod* 1997;83:393–399.
- [13] Liberda, Ondřej. Onemocnění čelistního kloubu- posouzení terapeutického efektu distenze a laváže čelistního kloubu. Brno, 2012. Atestační práce z oboru orální a

- maxilofaciální chirurgie. Klinika ústní, čelistní a obličejové chirurgie LF MU a FN Brno. Vedoucí práce Školitel: Doc. MUDr. Milan Machálka, CSc.
- [14] Stegenga B. Osteoarthritis of the temporomandibular joint organ and its relationship to disc displacement. *J Orofac Pain* 2001; 15 (3): 193– 205.
- [15] Magnusson T, Egermarki I, Carlsson GE. A prospective investigation over two decades on signs and symptoms of temporomandibular disorders and associated variables. A final summary. *Acta Odontol Scand* 2005; 63 (2): 99– 109.
- [16] Wilkes CH. Internal derangement of the temporomandibular joint pathological variations. *Arch Otolaryngol Head Neck Surg* 1989;115:469–77.
- [17] Clunie, David A, Jan Žižka. DICOM structured reporting. 1. vyd. Bangor, Pa.: PixelMed Pub., c2000, 394 p. ISBN 09-701-3690-0.
- [18] Nagy. I. Kršek P. Hustak. J., Voxel Model Creation of Human Tissues from CT and MRI Data for Biomechanical Applications: Proceedings, Euroconference Biosignal 2000, Brno, FE VUT Brno, 2000, 278-280, ISBN 80-214-1610-6
- [19] Bleck, J. S.:Neue Technologien in der Sonographie. *Orthopäde*, 31: 197–201, 2002.
- [20] Freiherr, G.: Challenges to obtaining 3-D information abound. *Diagn.Imaging (Suppl.)*, 16–19, 2000.
- [21] Goldberg, B. G., : Third dimension reveals world of new information. *Diagn. Imaging (Suppl.)*, 20, 2000.
- [22] Hrazdira, I.: *Stručné repetitorium ultrasonografie*. 1. vyd. Praha, Audioscan 2003, 112
- [23] Hrazdira, L., Mikulec, J.: Spatial Reconstruction in 3D Echographic Examination of the Locomotive Apparatus. *Sportsmen Vlaams tijdschrift voor sportgeneeskunde en sportwetenschappen*,95: 56, 2003.
- [24] Hrazdira,L.: Možnosti ultrazvukového vyšetřování a prostorových rekonstrukcí pohybového aparátu. Brno, Paido 2004, 87 s.
- [25] Hrazdira L.,Mikulec,J.: 3D Echographic examination of the locomotive apparatus (CD ROM). Brno, Paido 2004, 15 s.
- [26] Hrazdira, L. A Skotáková. 3D Ultrasonography for Examination of the Musculoskeletal System. 3D Ultrasonography for Examination of the Musculoskeletal System. 2006, č. 73, s. 414-420.
- [27] Zuna, Ivan a Lubomír POUŠEK. Úvod do zobrazovacích metod v lékařské diagnostice. Vyd. 1. Praha: Vydavatelství ČVUT, 2000, 76 s. ISBN 80-01-02152-1
- [28] Jan, Jiří. *Medical Image Processing, Reconstruction and Restoration: Concepts and Methods*. Boca Raton (FL, USA) : CRC Press, Taylor & Francis, 2006. xxiii, 730 s. ISBN 9780824758493.
- [29] Bracewell, R.N. (1990). "Numerical Transforms". *Science* 248 (4956): 697–704. doi:10.1126/science.248.4956.697. PMID 17812072.
- [30] Brenner DJ, Hall EJ (November 2007). "Computed tomography--an increasing source of radiation exposure". *N. Engl. J. Med.* 357 (22): 2277–84. doi:10.1056/NEJMra072149. PMID 18046031.
- [31] Davies, H. E.; Wathen, C. G.; Gleeson, F. V. (25 February 2011). "The risks of radiation exposure related to diagnostic imaging and how to minimise them". *BMJ* 342 (feb25 1): d947–d947.
- [32] Furlow, B (2010 May-Jun). "Radiation dose in computed tomography.". *Radiologic technology* 81 (5): 437–50. PMID 20445138.
- [33] Hall, EJ; Brenner, DJ (2008 May). "Cancer risks from diagnostic radiology.". *The British journal of radiology* 81 (965): 362–78. doi:10.1259/bjr/01948454. PMID 18440940.
- [34] Shrimpton, P.C; Miller, H.C; Lewis, M.A; Dunn, M. Doses from Computed Tomography (CT) examinations in the UK – 2003 Review

- [35] Válek, V., Eliáš, P., Petr Máca, J. N.: Moderní diagnostické metody-II. díl- Výpočetní tomografie. Institut pro další vzdělávání pracovníků ve zdravotnictví v Brně.
- [36] Sorapong Aootaphao, C. P.; Sotthivirat, S.: Penalized-Likelihood Reconstruction for Metal Artifact Reduction in Cone-Beam CT. In International IEEE EMBS Conference, 2008.
- [37] Drastich, A.: Tomografické zobrazovací systémy. První vydání, Vysoké učení technické v Brně, 2004, ISBN 80-214-2788-4, 208 s.
- [38] Feltlová, E., Dostálová, T., Kašparová, M., Daněk, J., Hlišáková, P., Hubáček, M., Nedoma, J. Temporomandibular Joint Prosthesis 3D-CT Reconstruction before and after Treatment. European Journal for Biomedical Informatics, 2010, roč. 6, č. 1, s. 15-19. ISSN: 1801-5603
- [39] Insight into images: principles and practice for segmentation, registration, and image analysis. Editor Terry S Yoo. Wellesley: A K Peters, c2004, xvi, 393 s. ISBN 15-688-1217-5.
- [40] Válek, Vlastimil a Jan Žižka. Moderní diagnostické metody. 1. vyd. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 1996, 43 s. ISBN 80-701-3225-6.
- [41] Viták, Tomáš et al. Základní artefakty diagnostického zobrazování metodou magnetické rezonance. Česká radiologie. Praha : 2000, roč. 54, č. 5, s. 323 –328. ISSN 1210-7883.
- [42] Viták, Tomáš et al. Artefakty v diagnostickém zobrazování magnetickou rezonancí – souvislost s principy metody. Lékař a technika. Praha : 2001, roč.32, č. 1, s. 18 – 21. ISSN 0301-5491.
- [43] Hurst, J, Robert A O'Rourke, Richard A Walsh a Valentin Fuster. Hurst's the heart manual of cardiology. 12th ed. New York: McGraw-Hill Medical, c2009, xxv, 750 p. ISBN 00-715-9298-9.
- [44] Peli, E. Contrast in complex images. J. Opt. Soc. Am. vol. 7, no. 10, October 1990.
- [45] Xiaomei, S., et col. Automated region detection based on the contrast-to-noise ratio in near-infrared tomography. Applied Optics, vol. 43, no. 5, s. 1053-1062, 2004.
- [46] Přinosil, J.; Smékal, Z.; Bartušek, K. Wavelet Thresholding Techniques in MRI Domain. In Proceedings of the First International Conference on Biosciences BioSciencesWorld 2010. IEEE Computer Society Conference Publishing Services, 2010. s. 58-63. ISBN: 978-0-7695-3968- 3.
- [47] Chang, S.G., Yu, B., And Vetterli, M.: Adaptive Wavelet thresholding for image denoising and compression, IEEE Transactions on Image Processing, vol. 9, pp. 1532-1546, 2000
- [48] Alexander, M.E., et. al.: A Wavelet-based Method for Improving Signal-to-noise Ratio and Contrast in MR Images, Magnetic Resonance Imaging, vol. 18, pp. 169-180, 2000.
- [49] Teolis A.. *Computational Signal Processing with Wavelets*. Birkhäuser, Boston, 1998
- [50] Braunish, H., Baeian, W., and Kong, J., A.: Phase Unwrapping of SAR Interferograms after Wavelet De-noising. IEEE Geoscience and Remote Sensing Symposium, vol. 2, pp. 752-754, 2000.
- [51] Donoho, D. L.: De-Noising by Soft-Thresholding, IEEE Transactions on information theory, vol. 41, 1995.
- [52] Tsomko, E.; Kim, H. J. Efficient Method of Detecting Globally Blurry or Sharp Images, Korea University, Department of Information Management and Security, 2008.
- [53] Kozumplík J., Vlnkové transformace a jejich využití pro filtraci signálu EKG, Habilitační práce, ÚBMI, FEKT, VUT v Brně, 2004.

- [54] LI, S. Z. Markov Random Field Modeling in Computer Vision. National Laboratory of Pattern Recognition, Institute of Automation, Chinese Academy of Science, 2001.
- [55] Marroquin, J. L., Santana, A., Botello, S. Hidden Markov Measure Field Models for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machina Inteligence*, vol. 25, no. 11.
- [56] Cootes, T. F., Edwards, G. J., Taylor, C. J. Active Appearance Models. In: *Proceedings of European Conference on Computer Vision*, 1998, vol. 2, Springer, 1998, s. 484-498.
- [57] Fukunaga, K. *Introduction to Statistical Pattern Recognition*. Elsevier. ISBN 0122698517.
- [58] Pednekar, A., Kakadiaris, I. A., Kurkure, U. Adaptive Fuzzy Connectedness-based Medical Image Segmentation. In: *Proceedings of the Indian Conference on Computer Vision, Graphics and Image Processing (ICVGIP 02)*, Space Applications Centre (ISRO), Ahmedabad, India, December 2002.
- [59] Wismüller, A., Vietze, F. et al. A Neural Network Approach to Adaptive Pattern Analysis - the Deformable Feature Map. In: *European Symposium on Artificial Neural Networks, ESANN'2000*, Bruges, Belgium, April 2000, s. 189-194.
- [60] Aubert, G., Kornprobst, P. *Mathematical problems in image processing :Partial differential equations and the calculus of variations*. 2nd edition. New York :Springer Science + Business Media, LLC, 2006, ISBN 0-387-32200-0.
- [61] Osher, S., Fedkiw, R. *Level Set Method and Dynamic Implicit Surfaces*. New York: Springer-Verlag New York, Inc., 2003, ISBN 0-387-95481-1.
- [62] Ayed, I. B., Mitiche, A. A Region Merging Prior for Variational Level Set Image Segmentation. *IEEE Transactions on Image Processing*, 2008, vol. 17, no. 12, s.2301-2311, ISSN 1057-7149.
- [63] Shi, Y., Karl, W., C. A Real-Time Algorithm for the Approximation of Level-Set-Based Curve Evolution. *IEEE Transactions on Image Processing*, 2008, vol. 17, no. 5,s. 645-655, ISSN 1057-7149.
- [64] Lorensen, W.E.; Cline, H.E. Marching cubes: a high resolution 3D surface construction algorithm. *Computer Graphics* 1987, 21(4):163–9.
- [65] Lewiner, Thomas; Lopes, Hélio; Vieira, Antônio W.; Tavares, Geovan: Efficient implementation of Marching Cubes' cases with topological guarantees. *Journal of Graphics Tools*. 2003, 8, 2, s. 1–15. ISSN: 1086-7651.
- [66] Chernyaev E. V.. *Marching Cubes 33: Construction of Topologically Correct Isosurfaces*. Technical Report CERN CN 95-17, CERN, 1995.
- [67] Hemmert S., Hutchings B., Malvi A. 2001. An Application-Specific Compiler for High-Speed Binary Image Morphology. In *Proceedings of the the 9th Annual IEEE Symposium on Field-Programmable Custom Computing Machines (FCCM '01)*. IEEE Computer Society, Washington, DC, USA, 199-208. DOI=10.1109/FCCM.2001.10 <http://dx.doi.org/10.1109/FCCM.2001.10>
- [68] Vincent, L., "Morphological Grayscale Reconstruction in Image Analysis: Applications and Efficient Algorithms," *IEEE Transactions on Image Processing*, Vol. 2, No. 2, April, 1993, pp. 176-201.
- [69] Vincent L.. *Algorithmes Morphologiques a Base de Files d'Attente et de Lacets: Extension aux Graphes*. PhD thesis, Ecole des Mines, Paris, May 1990.
- [70] Nobuyuki Otsu (1979). "A threshold selection method from gray-level histograms". *IEEE Trans. Sys., Man., Cyber.* 9 (1): 62–66. doi:10.1109/TSMC.1979.4310076
- [71] Fernand Meyer, *Topographic Distance and watershed lines*, *Signal Processing*, Volume 38, Issue 1, July 1994, Pages 113-125, ISSN 0165-1684, 10.1016/0165-1684(94)90060-4.

- [72] Neubauer, J, Sedlačík M., Kříž O.. Základy statistiky: aplikace v technických a ekonomických oborech. 1. vyd. Praha: Grada, 2012, 236 s. ISBN 978-80-247-4273-1.
- [73] Zelinka, Ivan, Zuzana Opletalová, Miloš Šeda, Pavel Ošmera a František Včelař. Evoluční výpočetní techniky: principy a aplikace. 1. české vyd. Praha: BEN, 2009, 534 s. ISBN 978-80-7300-218-3.
- [74] Lorensen WE, Cline HE: Marching cubes: A high resolution 3D surface construction algorithm. In SIGGRAPH '87: Proceedings of the 14th annual conference on Computer graphics and interactive techniques. Volume 21. New York, NY, USA: ACM Press; 163-169.
- [75] Schmid B, Schindelin J, Cardona A, Longair M, Heisenberg M: A high-level 3D visualization API for Java and ImageJ. BMC Bioinformatics 2010, 11:274.
- [76] Erwin Kreyszig (2005). Advanced Engineering Mathematics (9 ed.). Wiley. věst. 816. ISBN 9780471488859 .
- [77] Catmull, Edwin and Rom, Raphael, A class of local interpolating splines, in RE Barnhill and RF Riesenfeld (eds.) Computer Aided Geometric Design, Academic Press, New York, 1974, 317–326.
- [78] Vollmer J., Mencil R., Muller H., Improved laplacian smoothing of noisy surface meshes, Research report No. 711 /1999, June 1999
- [79] Dice, Lee R. (1945). "Measures of the Amount of Ecologic Association Between Species". Ecology 26 (3): 297–302. doi:10.2307/1932409. JSTOR 1932409
- [80] Egger J., Kapur T., Fedorov A., Pieper S., Miller J.V., Veeraraghavan H., Freisleben B., Golby A.J., Nimsky C., Kikinis R. GBM Volumetry using the 3D Slicer Medical Image Computing Platform. Sci Rep. 2013 Mar 4;3:1364. PMID: 23455483. PMCID: PMC3586703.
- [81] Mikulka, Jan. Segmentační metody ve zpracování biomedicinských obrazů. Brno, 2012. Dostupné z: https://www.vutbr.cz/studium/zaverecne-prace?zp_id=41918. Dizertační práce. Vysoké učení technické v Brně. Vedoucí práce Eva Gescheidtová.
- [82] Osher, Stanley a James A Sethian. Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations. ISBN [http://dx.doi.org/10.1016/0021-9991\(88\)90002-2](http://dx.doi.org/10.1016/0021-9991(88)90002-2).
- [83] Miao, Yu, Wei Li SHI, Karol Mikula, Alessandro Sarti A Fiorella Sgallari. Level Set Segmentation Method in Medical Image Segmentation Research and Application. ISBN http://dx.doi.org/10.1007/0-306-48551-6_11.
- [84] Terry, S Y. Insight into images: principles and practice for segmentation, registration, and image analysis. Wellesley: A K Peters, c2004, xvi, 393 s. ISBN 15-688-1217-5.
- [85] Cignoni, P., C. Rocchini a R. Scopigno. Metro: Measuring Error on Simplified Surfaces. Computer Graphics Forum. 1998, vol. 17, issue 2, s. 167-174. DOI: 10.1111/1467-8659.00236. Dostupné z: <http://doi.wiley.com/10.1111/1467-8659.00236>
- [86] Wang, Yingjie a Chin-Seng CHUA. Robust face recognition from 2D and 3D images using structural Hausdorff distance. Image and Vision Computing. 2006, vol. 24, issue 2, s. 176-185. DOI: 10.1016/j.imavis.2005.09.025. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0262885605001873>
- [87] Bajaj, Chandrajit, Andrew GILLETTE a Qin ZHANG. Stable mesh decimation. 2009 SIAM/ACM Joint Conference on Geometric and Physical Modeling on - SPM '09. 2009. DOI: <http://dx.doi.org/10.1145/1629255.1629290>.
- [88] Kircos T. L., Ortendahl A. D., Mark S. A., Arakawa M., Magnetic resonance imaging of the TMJ disc in asymptomatic volunteers, Journal of Oral and Maxillofacial Surgery, Volume 45, Issue 10, October 1987, Pages 852-854, ISSN 0278-2391, [http://dx.doi.org/10.1016/0278-2391\(87\)90235-7](http://dx.doi.org/10.1016/0278-2391(87)90235-7).

- [89] Dahlström, L a A M Lindvall. Assessment of temporomandibular joint disease by panoramic radiography: reliability and validity in relation to tomography. *Dentomaxillofacial Radiology*. 1996, vol. 25, issue 4, s. 197-201. DOI: 10.1259/dmfr.25.4.9084273. Dostupné z:<http://www.birpublications.org/doi/abs/10.1259/dmfr.25.4.9084273>
- [90] Nitzan W. D., Temporomandibular joint “open lock” versus condylar dislocation: Signs and symptoms, imaging, treatment, and pathogenesis, *Journal of Oral and Maxillofacial Surgery*, Volume 60, Issue 5, May 2002, Pages 506-511, ISSN 0278-2391, <http://dx.doi.org/10.1053/joms.2002.31846>
- [91] Tsiklakis, K, K Syriopoulos a HC Stamatakis. Radiographic examination of the temporomandibular joint using cone beam computed tomography. *Dentomaxillofacial Radiology*. 2004, vol. 33, issue 3, s. 196-201. DOI: 10.1259/dmfr/27403192.
- [92] Balliu, E, V Medina, JC Vilanova, I Peláez, J Puig, JM Trull a S Pedraza. Synovial chondromatosis of the temporomandibular joint: CT and MRI findings. *Dentomaxillofacial Radiology*. 2007, vol. 36, issue 1, s. 55-58. DOI: 10.1259/dmfr/89319561. Dostupné z: <http://www.birpublications.org/doi/abs/10.1259/dmfr/89319561>
- [93] Zeliha Kapusuz Gencer, Mahmut Özkiriş, Aylin Okur, Murat Korkmaz, Levent Saydam, A comparative study on the impact of intra-articular injections of hyaluronic acid, tenoxicam and betametazon on the relief of temporomandibular joint disorder complaints, *Journal of Cranio-Maxillofacial Surgery*, 2014,
- [94] Mark D. Litt, Felipe B. Porto, Determinants of Pain Treatment Response and Nonresponse: Identification of TMD Patient Subgroups, *The Journal of Pain*, 2013, 14, 11, 1502
- [95] K. I. Reid, C. S. Greene, Diagnosis and treatment of temporomandibular disorders: an ethical analysis of current practices, *Journal of Oral Rehabilitation*, 2013, 40, 7
- [96] H.-Y. Cheng, P.-W. Peng, Y.-J. Lin, S.-T. Chang, Y.-N. Pan, S.-C. Lee, K.-L. Ou, W.-C. Hsu, Stress analysis during jaw movement based on vivo computed tomography images from patients with temporomandibular disorders, *International Journal of Oral and Maxillofacial Surgery*, 2013, 42, 3, 386
- [97] Hirofumi Y., Historical Transition of Prosthodontic Treatments for Temporomandibular Disorders with Special Reference to Splint Therapy, Occlusal Adjustments, and Occlusal Reconstruction, *Annals of Japan Prosthodontic Society*, 2012, 4, 3, 229
- [98] Chao Lu; Chelikani, S.; Jaffray, D.A.; Milosevic, M.F.; Staib, L.H.; Duncan, J.S. "Simultaneous Nonrigid Registration, Segmentation, and Tumor Detection in MRI Guided Cervical Cancer Radiation Therapy", *Medical Imaging, IEEE Transactions on*, On page(s): 1213 - 1227 Volume: 31, Issue: 6, June 2012
- [99] Juntao Ye; Guoliang Xu "Geometric Flow Approach for Region-Based Image Segmentation", *Image Processing, IEEE Transactions on*, On page(s): 4735 - 4745 Volume: 21, Issue: 12, Dec. 2012
- [100] Weingart, M.; Vascan, O. "Image segmentation processing - some techniques and experimental results: A study of the experimental results of some segmentation techniques", *Electrical and Electronics Engineering (ISEEE), 2013 4th International Symposium on*, On page (s): 1 - 8

Seznam příspěvků autora

MIKULKA, J.; ŠMIRG, O.; GALLEGO, D.; ESPÍN, F.; GIL, V.; FAÚNDEZ ZANUY, M.; JIMÉNEZ, M.; CLAVÉ, P. In vitro motor patterns and electrophysiological changes in patients with colonic diverticular disease. *INTERNATIONAL JOURNAL OF COLORECTAL DISEASE*, 2013, roč. 2013, č. 5, s. 1-34. ISSN: 0179- 1958.

ŠMIRG, O.; SMÉKAL, Z.; DUTTA, M.; KAKANI, B. Automatic Detection of the Direction and Speed of Moving Objects in the Video. In *Sixth International Conference on Contemporary Computing*. 2013. s. 86-90. ISBN: 978-1-4799-0190- 6.

ŠMIRG, O.; SMÉKAL, Z.; LIBERDA, O. Automated Detection of Important Facial Curves in Radiographs. In *36th International Conference on Telecommunications and Signal Processing*. Vutium, 2013. s. 778-782. ISBN: 978-1-4799-0402- 0.

ŠMIRG, O.; SMÉKAL, Z.; LIBERDA, O. Zvýraznění významných oblastí dolní a horní čelisti. In *Nové směry v biomedicinském inženýrství*. Brno: VUT Brno, 2013. s. 27-36. ISBN: 978-80-214-4814- 8.

ŠMIRG, O.; SMÉKAL, Z. Real- time Detection of Human Body in Videos. In *Vutium*, 2012. s. 784-788. ISBN: 978-1-4673-1116- 8.

SMÉKAL, Z.; ŠMIRG, O.; LIBERDA, O.; ŠPRLÁKOVÁ, A. MRI Slice Segmentation and 3D Modelling of Temporomandibular Joint Measured by Microscopic Coil. *Measurement Science Review*, 2012, roč. 2012, č. 3, s. 74-81. ISSN: 1335- 8871.

SMÉKAL, Z.; BURGET, R.; BENEŠ, R.; ŘÍHA, K.; PŘINOSIL, J.; MEKYSKA, J.; ZUKAL, M.; ŠMIRG, O.; ČÍKA, P. Výzkum algoritmů pro zpracování digitálních obrazů a obrazových sekvencí - závěrečná výzkumná zpráva projektu ME 10123. Brno: VUT, 2012.

SMÉKAL, Z.; BURGET, R.; BENEŠ, R.; ŘÍHA, K.; PŘINOSIL, J.; MEKYSKA, J.; ZUKAL, M.; ŠMIRG, O.; ČÍKA, P. Výzkum algoritmů pro zpracování digitálních obrazů a obrazových sekvencí, dílčí výzkumná zpráva projektu MSM/ ME10123 za rok 2011. Brno: VUT, 2011.

ŠMIRG, O.; SMÉKAL, Z.; FAÚNDEZ ZANUY, M. Detection of Ankle Position in Human Silhouette in a Video Sequence. In *6th International Conference on Teleinformatics*. Dolní Morava: VUT, 2011. s. 188-192. ISBN: 978-80-214-4231- 3.

ŠMIRG, O.; SMÉKAL, Z.; FAÚNDEZ ZANUY, M. Measurement of joint position for human recognition by locomotion. *Elektrorevue - Internetový časopis* (<http://www.elektrorevue.cz>), 2011, roč. 2011, č. 2, s. 1-5. ISSN: 1213- 1539.

ŠMIRG, O.; SMÉKAL, Z.; LIBERDA, O.; ŠPRLÁKOVÁ, A. Creating a 3D Model of the Temporomandibular Joint Disc on the Basis of Segmented MRI Slices. In *TSP 2011*. Vutium, 2011. s. 369-375. ISBN: 978-1-4577-1409- 2.

GRASSI, M.; FAÚNDEZ ZANUY, M.; MIKULKA, J.; ŠMIRG, O. Face Gender Recognition Using Neural Networks and DCT Images Coefficient Selection. In *Itálie: IOS Press*, 2011. s. 255-261. ISBN: 1607509717.

BURGET, R.; ŠMIRG, O.; KERKOVSKÝ, M.; SMÉKAL, Z.; ŠPRLÁKOVÁ, A. Automatic segmentation of focal lesions in the brain using artificial intelligence methods. In 13th International Conference on Research in Telecommunication Technologies. Těchov: 2011. s. 179-182. ISBN: 978-80-214-4283- 2.

ŠMIRG, O.; FAÚNDEZ ZANUY, M.; GRASSI, M.; MEKYSKA, J.; MIKULKA, J. Gender Recognition Using PCA and DCT of Face Images. Lecture Notes in Computer Science, 2011, roč. 6692, č. 6, s. 220-227. ISSN: 0302- 9743.

HANÁK, P.; VRBA, K.; ŠMIRG, O. Ampere- Range Linear Voltage Controlled Current Source and Generator ZS1. In The 33rd International Conference on Telecommunications and Signal Processing. 1. Szent Ustvan krt. 7, Budapest: Asszisztencia Szerverzo Kft., 2010. s. 18-22. ISBN: 978-963-88981-0- 4.

ŠMIRG, O.; SMÉKAL, Z.; ČÍKA, P.; MÍČA, I. A methods for recognition and separation human body. Elektrovue - Internetový časopis (<http://www.elektrovue.cz>), 2010, roč. 2010, č. 11, s. 1-6. ISSN: 1213- 1539.

ŠMIRG, O.; ČÍKA, P.; SMÉKAL, Z.; MÍČA, I. Human body detection in a video scene. In The 33rd International Conference on TELECOMMUNICATIONS AND SIGNAL PROCESSING. 1. Szent Ustvan krt. 7, Budapest: Asszisztencia Szerverzo Kft., 2010. s. 160-165. ISBN: 978-963-88981-0- 4.

SMÉKAL, Z.; BURGET, R.; BENEŠ, R.; ŘÍHA, K.; PŘINOSIL, J.; MEKYSKA, J.; ZUKAL, M.; ŠMIRG, O.; ČÍKA, P. Výzkum algoritmů pro zpracování digitálních obrazů a obrazových sekvencí, dílčí výzkumná zpráva projektu MSM/ ME10123 za rok 2010. Brno: VUT, 2010.

ŠMIRG, O.; SMÉKAL, Z.; MÍČA, I. Extraction of polynomial model of temporomandibular condyl. In International Conference NEW INFORMATION AND MULTIMEDIA TECHNOLOGIES NIMT - NIMT 2010. Brno: VUT Brno, 2010. s. 17-21. ISBN: 978-80-214-4126- 2.

ČÍKA, P.; ZUKAL, M.; ŠMIRG, O. Java Based Voice over IP Softphone. In The 33rd International Conference on Telecommunications and Signal Processing - TSP 2010. Szent Ustvan krt. 7, Budapest: Asszisztencia Szerverzo, 2010. s. 1-4. ISBN: 978-963-88981-0- 4

ŠMIRG, O.; SMÉKAL, Z.; ŠPRLÁKOVÁ, A.; LIBERDA, O. Enhancement of Sonographic Images of Temporomandibular Joint Using the Wavelet Transform. In International Conference NEW INFORMATION AND MULTIMEDIA TECHNOLOGIES NIMT - NIMT 2009. 2009. s. 55-57. ISBN: 978-80-214-3930- 6.

ŠMIRG, O.; KOHOUTEK, M. Automatické zaostřování světlometu. Elektrovue - Internetový časopis (<http://www.elektrovue.cz>), 2009, roč. 2009, č. 1, s. 1-8. ISSN: 1213- 1539.

ŠMIRG, O. Detekce lidské postavy v obrazové scéně. In Student EEICT 2008. Brno: VUT, 2008. s. 24-27. ISBN: 978-80-214-3615- 2.

ŠMIRG, O.; MÍČA, I. Moving Object Detection in Video Sequences using Modified Mixture of Gaussians. International Transaction on Computer Science and Engineering, 2008, roč. 2008, č. 1, s. 117-125. ISSN: 1738- 6438.

Seznam obrázků

OBR. 1.1: KLOUBNÍ HLAVICE (VLEVO OKROUHLÝ TVAR, VPRAVO PLOCHÝ TVAR) - PŘEVZATO ZE ZDROJE [13].....	13
OBR. 1.2: ANATOMIE TEMPOROMANDIBULÁRNÍHO KLOUBU PŘI ZAVŘENÝCH ÚSTECH [12].....	14
OBR. 1.3: PRINCIP VYHODNOCENÍ PATOLOGICKÉ POZICE DISKU [12].....	14
OBR. 1.4: PRINCIP VYHODNOCENÍ PATOLOGICKÉ POZICE DISKU PODLE STUDIE VE ZDROJI [12].....	15
OBR. 1.5: POUZDRO TMK TVOŘENÉ TEMPOROMANDIBULÁRNÍM LIGAMENTEM [13].....	15
OBR. 1.6: ROZFÁZOVANÝ POHYB ČELISTI U DISLOKACE DISKU S REPOZICÍ [13].....	16
OBR. 1.7: ROZFÁZOVANÝ POHYB ČELISTI U DISLOKACE DISKU BEZ REPOZICE [13].....	17
OBR. 1.8: VYMEZENÁ OBLAST MOŽNÉHO VÝSKYTU DISKU PRO ZDRAVÝ I DISLOKOVANÝ DISK.....	18
OBR. 2.1: BLOKOVÉ SCHÉMA TVORBY TROJROZMĚRNÉHO OBJEKTU TKÁNÍ.....	19
OBR. 2.2: MPR ZOBRAZENÍ HILL-SACHSŮVA DEFEKTU HLAVICE HUMERU [26].....	20
OBR. 2.3: PROSTOROVÁ REKONSTRUKCE KOSTĚNÉHO POVRCHU TRÍŠTIVÉ ZLOMENINY.....	21
OBR. 2.4: 3D MODEL Z CT V PROGRAMU CTVILREGAPP.....	25
OBR. 2.5: 3D MODEL TUMORU V MOZKU POMOCÍ PROGRAMU 3D DOCTOR (ZDROJ:WWW.ABLESW.COM/).....	28
OBR. 2.6: BLOKOVÉ SCHÉMA JEDNOHO STUPNĚ DEKOMPOZICE OBRAZU 2D DTWT.....	32
OBR. 2.7: UKÁZKA INDEXOVÁNÍ A) VRCHOLŮ KRYCHLE B) HRAN KRYCHLE.....	42
OBR. 2.8: ZÁKLADNÍ STAVY KRYCHLE METODY MARCHING CUBES.....	43
OBR. 4.1: PŘÍKLAD MRI OBRAZU PRO SEGMENTACI KLOUBNÍ HLAVICE.....	45
OBR. 4.2: ZPRACOVÁNÍ OBRAZU POMOCÍ FILTRU VYUŽÍVAJÍCÍHO MORFOLOGICKÉ OPERACE....	48
OBR. 4.3: REGIONÁLNÍ MAXIMA OVLIVNĚNÁ LOKÁLNÍM ŠUMEM.....	49
OBR. 4.4: ZNAČKY POPŘEDÍ ZOBRAZENÉ V MRI OBRAZE HLAVY.....	50
OBR. 4.5: OBLASTI PRO VÝPOČET POZADÍ ZÍSKANÉ METODOU OTSU.....	52
OBR. 4.6: ZNAČKY POZADÍ VYTVOŘENÉ ZA POMOCÍ DIRICHTELOVY TESELACE.....	52
OBR. 4.7: ZNAČKY POZADÍ VYTVOŘENÉ POMOCÍ DISTANČNÍHO ALGORITMU.....	53
OBR. 4.8: UKÁZKA ZNAČEK POZADÍ V OBLASTI KLOUBNÍ HLAVICE (VLEVO - DIRICHTELOVA TESELACE, VPRAVO - DISTANČNÍ ALGORITMUS [71]).....	53
OBR. 4.9: UKÁZKA SEGMENTACE KLOUBNÍ HLAVICE (VLEVO - DIRICHTELOVA TESELACE, VPRAVO - DISTANČNÍ ALGORITMUS [71]).....	54
OBR. 4.10: PRINCIP VYMEZENÍ OBLASTI PRAVDĚPODOBNÉHO VÝSKYTU DISKU.....	55
OBR. 4.11: VIZUALIZACE VÝŘEZU OBLASTI S DISKEM A NÁVAZNOSTI JEDNOTLIVÝCH VRSTEV..	56
OBR. 4.12: PRAVDĚPODOBNOSTNÍ MODEL SPOJITOSTI JEDNOTLIVÝCH ŘEZŮ.....	58
OBR. 4.13: MASKA JÁDRA KLOUBNÍHO DISKU, KTERÁ JE SPOLEČNÁ PRO VŠECHNY VRSTVY....	59
OBR. 4.14: GRAFICKÉ VYJÁDŘENÍ PROBLÉMU SEGMENTACE DISKU POMOCÍ HISTOGRAMU.....	60
OBR. 4.15: HISTOGRAM MEZIKRUŽÍM OMEZENÉ ČÁSTI OBRAZU.....	60
OBR. 4.16: UKÁZKA PRAVDĚPODOBNOSTNÍ FUNKCE ŠUMU Z OBLASTI OZNAČENÉ NA MRI.....	61
OBR. 4.17: PŘÍKLAD SMĚSI DVOU GAUSOVÝCH KŘIVEK S KONSTANTNÍ SMĚRODATNOU ODCHYLKOU A ČETNOSTÍ.....	63
OBR. 4.18: GRAF FUNKCE PROHLEDÁVANÉHO PODPROSTORU.....	63
OBR. 4.19: GRAF FUNKCE OMEZENÉHO PROHLEDÁVANÉHO PODPROSTORU.....	65
OBR. 4.20: UKÁZKA FUNKCE SELEKCE PRO PŘEPOČET VHODNOSTI JEDINCŮ NA SKÓRE.....	66
OBR. 4.21: GRAF VÝVOJE ÚČELOVÉ FUNKCE PO 100 GENERACÍ GENETICKÉHO ALGORITMU PRO 2 GAUSOVY KŘIVKY.....	67
OBR. 4.22: PŘÍKLAD GAUSOVÝCH KŘIVEK ZÍSKANÝCH POMOCÍ GENETICKÉHO ALGORITMU....	68
OBR. 4.23: POROVNÁNÍ PRAVDĚPODOBNOSTNÍ FUNKCE HISTOGRAMU (ZELENÁ) SE SMĚSÍ DVOU NALEZENÝCH GAUSOVÝCH KŘIVEK (MODRÁ).....	68
OBR. 4.24: POROVNÁNÍ PRAVDĚPODOBNOSTNÍ FUNKCE HISTOGRAMU (ZELENÁ) SE SMĚSÍ PĚTI NALEZENÝCH GAUSOVÝCH KŘIVEK (MODRÁ).....	69

OBR. 4.25: GRAF VÝVOJE ÚČELOVÉ FUNKCE PO 100 GENERACÍ GENETICKÉHO ALGORITMU PRO 5 GAUSOVÝCH KŘIVEK	70
OBR. 4.26: UKÁZKA PĚTI GAUSOVÝCH KŘIVEK ZÍSKANÝCH POMOCÍ GENETICKÉHO ALGORITMU 70	
OBR. 4.27: UKÁZKA VZÁJEMNÉ POLOHY ŘEZŮ MEZI SAGITÁLNÍ A KORONÁLNÍ ROVINOU	71
OBR. 4.28: PRINCIP UKLÁDÁNÍ POZICE VOXELŮ PRO JEDNOTLIVÉ ŘEZY MRI	73
OBR. 4.29: 3D MODEL PŘI ZÁKLADNÍM POUŽITÍ METODY MARCHING CUBES	74
OBR. 4.30: GRAFICKÉ VYJÁDŘENÍ NEURČITOSTI MEZI JEDNOTLIVÝMI ŘEZY	74
OBR. 4.31: GRAFICKÉ VYJÁDŘENÍ PRINCIPU INTERPOLACE V OSE Z	75
OBR. 4.32: POROVNÁNÍ INTERPOLAČNÍCH METOD PRO JEDNOTLIVÉ ŘEZY	76
OBR. 4.33: MODEL KLOUBNÍ HLAVICE PŘI POUŽITÍ INTERPOLOVANÝCH ŘEZŮ METODOU KUBICKÝCH SPLAJNŮ	77
OBR. 4.34: MODEL KLOUBNÍ HLAVICE PO DECIMACI POLYGONÁLNÍ SÍTĚ O 50%	77
OBR. 4.35: VYHLAZENÝ MODEL KLOUBNÍ HLAVICE POMOCÍ METODY LAPALCIAN+HC	78
OBR. 5.1: POROVNÁNÍ MR ŘEZU BEZ POUŽITÍ MIKROSKOPICKÉ CÍVKY (VLEVO) A S POUŽITÍM MIKROSKOPICKÉ CÍVKY (VPRAVO)	80
OBR. 5.2: SROVNÁNÍ SNR PODLE POUŽITÝCH MATEŘSKÝCH VLNEK A TYPŮ PRAHOVÁNÍ	82
OBR. 5.3: DETAIL KLOUBNÍ HLAVICE PŘED A PO FILTRACI ZA POMOCÍ VLNKOVÉ TRANSFORMACE	82
OBR. 5.4: UKÁZKA KONDYLU S NEOSTROU HRANICÍ	84
OBR. 5.5: UKÁZKA TŘÍ MASEK RUČNÍCH SEGMENTACÍ A VPRAVO DOLE MASKA JEJICH PRŮMĚRU	85
OBR. 5.6: ZÁVISLOST SØRENSEN–DICE KOEFICIENTU NA KOEFICIENTU ROZPÍNÁNÍ PRO MĚŘENÝ KONDYL	88
OBR. 5.7: ZÁVISLOST SØRENSEN–DICE KOEFICIENTU NA KOEFICIENTU ZAKŘIVENÍ PRO MĚŘENÝ KONDYL	88
OBR. 5.8: ZÁVISLOST SØRENSEN–DICE KOEFICIENTU NA KOEFICIENTU ZAKŘIVENÍ PRO MĚŘENÝ KONDYL	89
OBR. 5.9: GRAF VALIDACE HODNOTY KOEFICIENTU ROZPTYLU JASU PRO KONDYL	89
OBR. 5.10: ZÁVISLOST SØRENSEN–DICE KOEFICIENTU NA KRITÉRIU KONVERGENCE U SEGMENTACE KONDYLU	90
OBR. 5.11: PRŮBĚH KONVERGENCE KE STANOVENÉMU KRITÉRIU ALGORITMU LEVEL SET S NALEZENÝMI PARAMETRY PRO KONDYL	91
OBR. 5.12: UKÁZKA VÝSLEDKŮ SEGMENTACE (ZELENÁ-RUČNÍ SEGMENTACE, ČERVENÁ – VLASTNÍ ALGORITMUS, MODRÁ – LEVEL SET FUNKCE)	92
OBR. 5.13: UKÁZKA ROZDÍLU MEZI RUČNÍ SEGMENTACÍ(ZELENÁ) A LEVEL-SET FUNKCÍ(MODRÁ) U KONDYLU	93
OBR. 5.14: UKÁZKA PŮVODNÍHO OBRAZU A RUČNĚ OZNAČENÉ OBLASTI KLOUBNÍHO DISKU	93
OBR. 5.15: PRŮBĚH KONVERGENCE KE STANOVENÉMU KRITÉRIU ALGORITMU LEVEL SET S NALEZENÝMI PARAMETRY PRO KLOUBNÍ DISK	94
OBR. 5.16: UKÁZKA VYMEZENÉ OBLASTI SPOČÍTANÁ ALGORITMEM, KDE SE NACHÁZÍ KLOUBNÍ DISK 95	
OBR. 5.17: UKÁZKA PRAVDĚPODOBNOSTNÍHO MODELU VÝSKYTU KLOUBNÍHO DISKU	96
OBR. 5.18: POROVNÁNÍ PRŮMĚRNÉ RUČNÍ SEGMENTACE KLOUBNÍHO DISKU S NAVRŽENOU METODOU	97
OBR. 5.19: UKÁZKA VYPOČTENÝCH VZORKŮ VZNIKLYCH NADVZORKOVÁNÍM MEZI DVĚMA PŮVODNÍMI VZORKY	98
OBR. 5.20: UKÁZKA ZMĚNY VELIKOSTI KOSTKY A TÍM ROZLIŠENÍ U METODY POHYBUJÍCÍ SE KOSTKA (MARCHING CUBES)	99

OBR. 5.21: UKÁZKA DECIMOVANÉHO MODELU KONDYLU S BAREVNÝM ROZLIŠENÍM HAUSDORFFOVY VZDÁLENOSTI (PROCENTA URČUJÍ POMĚR POČTU POLYGONŮ K JEJICH POČTU U PŮVODNÍHO MODELU)	101
OBR. 5.22: UKÁZKA VLIVU METODY LAPLACIAN HC 0 AŽ 7 ITERACÍ.....	102
OBR. 5.23: UKÁZKA VLIVU METODY LAPLACIAN HC POMOCÍ BAREVNÉHO VYKRESLENÍ D_H PRO ITERACE 0 AŽ 8	103
OBR. 5.24: UKÁZKA VÝVOJE D_H PRO ITERACE METODY LAPLACIAN HC	104
OBR. 5.25: UKÁZKA VÝSLEDNÉHO 3D MODELU PŘI OTÁČENÍ V OSE Y VŽDY POSUNUTÉ O 40°	105
OBR. 5.26: MODEL ČELISTNÍHO KLOUBU VYTIŠTĚNÝ POMOCÍ 3D TISKÁRNY ZPRINTER 650 ...	106

Seznam tabulek

TAB. 1.1: WILKESOVA KLASIFIKACE DISKOPATÍ [13][16].....	18
TAB. 2.1: HOUNSFIELDOVA STUPNICE [35]	23
TAB. 2.2: HODNOTY VSTŘEBANÉHO IONIZUJÍCÍHO ZÁŘENÍ RŮZNÝCH CT VYŠETŘENÍ.....	23
TAB. 2.3: PŘEHLED VLASTNOSTÍ TŘECH ZÁKLADNÍCH MATEŘSKÝCH VLNEK.....	32
TAB. 2.4: VÝSLEDKY SNR V [dB] PRO RŮZNÉ TYPY VLNEK A PRAHOVÁNÍ [46]	34
TAB. 4.1: HODNOTY ŠTÍTKŮ DICOM SOUBORU PRO JEDNOTLIVÉ ŘEZY	73
TAB. 5.1: PARAMETRY NMR.....	79
TAB. 5.2: POROVNÁNÍ PARAMETRŮ SEKVENČÍ.....	79
TAB. 5.3: VÝSLEDKY SNR PRO VYBRANÉ PARAMETRY WAVELETOVÉ FILTRACE	81
TAB. 5.4: PARAMETRY PRO SEGMENTACI KONDYLU METODOU S LEVELSET FUNKCÍ.....	90
TAB. 5.5: TABULKA SØRENSEN–DICE KOEFICIENTU PRO KONDYL.....	91
TAB. 5.6: PARAMETRY PRO SEGMENTACI DISKU METODOU S LEVEL-SET FUNKCÍ	94
TAB. 5.7: SØRENSEN–DICE KOEFICIENTY PRO KLOUBNÍ DISK.....	96
TAB. 5.8: TABULKA NAMĚŘENÝCH HODNOT D_H PRO RŮZNÉ HLOUBKY DECIMACE.....	100
TAB. 5.9: PARAMETRY 3D TISKÁRNY	106

Curriculum Vitae

OSOBNÍ INFORMACE:

Jméno: Ing. Ondřej Šmirg
Narozen: 8.5.1984
Email: smirg@feec.vutbr.cz
Telefon: +420 607 148 587

VZDĚLÁNÍ:

2008 - 2014 Ústav telekomunikací,
Vysoké učení technické v Brně,
Doktorský studijní program
2006 - 2008 Ústav telekomunikací,
Vysoké učení technické v Brně,
Magisterský studijní program
2003 - 2006 Ústav telekomunikací,
Vysoké učení technické v Brně,
Bakalářský studijní program

PRAXE:

2012 Soubor přednášek na University of South California, USA
2011 - 2014 Odborný asistent Ústavu telekomunikací, FEKT VUT v Brně
(plný úvazek).
2010 - 2011 Stáž na Universitat Politècnica de Catalunya, Španělsko
2008 - 2010 Asistent Ústavu telekomunikací, FEKT VUT v Brně
(částečný úvazek).

ÚČAST NA ŘEŠENÍ PROJEKTŮ:

2014 Kognitivní multimediální analýza zvukových a obrazových signálů Interní projekt VUT v Brně, reg.č.FEKT-S-14-2335
2013 – 2014 COST IC1206 De-Identification for Privacy Protection in Multimedia Content
2012-2014 NT13499-4/2012 Řeč, její poruchy a kognitivní funkce u Parkinsonovy nemoci
2012 – 2014 GAČR 102/12/1104 Study of metabolism and localization of high grade glioma using MR imaging techniques
2011 – 2014 FR-TI3/170 Inteligentní videomoduly pro systémy kontroly vstupů do objektů kritické infrastruktury
2010 – 2014 MV VG20102014033 Zvyšování účinnosti zabezpečení rizikových prostor kombinovanými metodami biometrické identifikace osob
2010 – 2013 Centrum sensorických, informačních a komunikačních systémů (SIX). Operační program Věda a výzkum pro inovace, reg.č. CZ.1.05/2.1.00/03.0072.
2008-2010 Výzkum a vývoj internetové telefonní ústředny. MPO reg.č. FT-TA3/011.

DALŠÍ VÝSLEDKY V ČÍSLECH

Počet příspěvků na vědeckých konferencích	23
Počet příspěvků v imputovaných časopisech	2
Počet softwaru	1
Počet registrovaných prototypů a funkčních vzorků	3
Počet úspěšně vedených bakalářských a diplomových prací	10