

Západočeská univerzita v Plzni  
Fakulta aplikovaných věd  
Katedra informatiky a výpočetní techniky

## **Bakalářská práce**

# **Nástroje pro vytváření 3D modelů člověka**

# Prohlášení

Prohlašuji, že jsem bakalářskou práci na téma

„Nástroje pro vytváření 3D modelů člověka.“

vypracovala samostatně pod odborným dohledem vedoucího bakalářské práce a výhradně s použitím uvedených zdrojů.

V Plzni, dne 4. 5. 2016

.....

podpis autora

## **Poděkování**

Na tomto místě bych ráda poděkovala vedoucímu práce panu docentu Josefu Kohoutovi za cenné připomínky a odborné rady, kterými přispěl k vypracování této bakalářské práce. Dále děkuji Evě Čížkové a panu doktorovi Jindřichu Čížkovi za expertní pomoc v oboru anatomie.

## **Abstrakt**

Bakalářská práce se zabývá základním procesem analýzy obsahu obrazových dat, segmentací. Hlavním cílem práce bylo srovnat dostupné segmentační nástroje, jež vyhovují podmínkám pro vytvoření 3D modelů kůže, svalů a kostí dolních končetin a pánevní oblasti.

Ve vybraném nástroji MeVisLab byly implementovány různé postupy segmentace. Pro medicínská obrazová data z projektu Visible Human Project se ukázalo, že k segmentaci kůže lze použít automatický postup založený na prahování. Vzhledem k povaze dat bylo u segmentace kostí a svalů nutné využít interaktivní přístup.

## **Abstract**

Presented Bachelor thesis focuses on image segmentation. The main objective was to compare available segmentation tools that meet the requirements for creating 3D models of skin, muscles and bones of the lower limbs and anatomy pelvic region from the Visual Human Project medical images.

Diverse methods of segmentation were implemented in the tool MeVisLab. Automatic thresholding method can be used for segmentation of the skin of medical images from the Visible Human Project but it was necessary to use the interactive approach for segmentation of bones and muscles.

# Obsah

1. Úvod.....	1
2. Zpracování obrazu .....	2
2.1. Snímání a digitalizace obrazu .....	2
2.2. Předzpracování obrazu .....	3
2.3. Obrazová segmentace.....	3
3. Segmentace medicínských obrazových dat .....	4
3.1. Zobrazovací metody (medical imaging) .....	4
3.1.1. Počítačová tomografie (computed tomography CT) .....	5
3.1.2. Magnetická resonance (magnetic resonance imaging MRI).....	5
3.1.3. Visible Human Project.....	5
3.2. Přístupy k segmentaci obrazových dat.....	5
3.2.1. Metody vycházející z detekce hran (edge-based).....	8
3.2.2. Metody orientované na regiony v obraze (region-based) .....	14
3.2.3. Statistické metody.....	14
3.2.4. Hybridní metody .....	16
3.2.5. Znalostní (knowledge-based).....	16
3.2.6. Souhrn metod.....	17
4. Nástroje pro segmentaci medicínských obrazových dat.....	18
4.1. MeVisLab.....	18
4.2. 3D-DOCTOR .....	20
4.3. TurtleSeg .....	22
4.4. ITK-SNAP.....	23
4.5. Zhodnocení nástrojů.....	24
5. MeVisLab .....	26
5.1. Moduly .....	26

5.2.	Moduly určené k načtení dat .....	27
5.2.1.	Definice oblasti zájmu (ROI - Region Of Interest) .....	28
5.3.	Moduly určené k segmentaci dat.....	28
5.4.	Moduly určené k vizualizaci dat .....	29
6.	Navržené řešení.....	30
6.1.	Obecný postup segmentace objektu .....	31
6.1.1.	Segmentace kůže .....	33
6.1.2.	Segmentace kostí, svalů.....	36
7.	Dosažené výsledky .....	40
7.1.	Model kůže.....	41
7.2.	Modely kostí.....	42
7.3.	Modely svalů.....	44
8.	Zhodnocení práce s nástroje MeVisLab .....	46
9.	Závěr .....	48
	Seznam pojmů a zkratk .....	50
	Seznam obrázků.....	51
	Seznam tabulek .....	53
	Literatura.....	54
	Seznam příloh .....	56
	Přílohy.....	57

# 1. Úvod

Pro určení lékařské diagnózy, predikci a prevenci nejrůznějších onemocnění je nezbytné získat různá medicínská data, z nichž velmi významnou část tvoří medicínské snímky. Obrazová data mohou poskytovat prezentaci vnitřních struktur, které nejsou bez řezu do lidského těla viditelné.

Snímky je možné pořídít několika způsoby a mohou mít různý charakter (2D nebo 3D). 3D obrazová data se získávají například magnetickou rezonancí nebo počítačovou tomografií. Mezi metody, které poskytují 2D obrazová data, patří zejména ultrazvuk nebo rentgenové záření. Pro účely zpracování této práce jsou k dispozici 2D obrazová data, která vznikla v rámci projektu Visible Human Project.

Úvodní kapitola se věnuje tématu, jak se obrazová informace zpracovává a rozpoznává, aby odpovídala obrazu reálného světa. Součástí zpracování medicínských snímků je předzpracování a analýza obrazu.


V následující kapitole je popsán jeden ze základních procesů analýzy obrazových dat, segmentace. Definují se zde jednotlivé přístupy, které rozdělí oblasti obrazu na jednotlivé objekty. V minulosti bylo navrženo mnoho metod segmentace, mezi základní patří prahování, segmentace narůstáním oblastí nebo metoda aktivních kontur. Algoritmy prošly mnohými modifikacemi a vylepšeními. Leckteré z nich byly implementovány a integrovány do nejrůznějších nástrojů, které se využívají nejen v lékařství, kde se pomocí nich určují lékařské diagnózy či abnormality, ale také v oblasti vědy a výzkumu.

Na katedře informatiky a výpočetní techniky na Západočeské univerzitě v Plzni je předmětem projektu 3D Human Body vytvořit za pomoci těchto nástrojů počítačový model člověka. Kosti, svaly a další části těla budou prezentovány povrchovým modelem.

Klíčovou kapitolou je popis a zhodnocení segmentačních nástrojů, které vyhovují podmínkám pro vytvoření modelu. Vybranými nástroji jsou MeVisLab, 3D-DOCTOR, TurtleSeg a ITK-SNAP. Cílem je seznámit se s danými programy a vyzkoušet jejich funkce. Hodnocení zahrnuje uživatelský pohled, použité metody segmentace, možnost rozšiřitelnosti a cenovou dostupnost. Na základě zhodnocení se poté vybere nejvíce vyhovující nástroj, kterým se budou modely vytvářet.

## 2. Zpracování obrazu

Obrazová informace musí být nejdříve zpracována a rozpoznána. Cílem je porozumění obsahu [1]. Postup se rozděluje do několika základních kroků, mezi které patří snímání a digitalizace obrazu, předzpracování, segmentace a popis a klasifikace objektů [2]. Obrázek č. 1 znázorňuje snímky ze scanneru, segmentaci a následný 3D model.




Obrázek 1 - Zpracování obrazu<sup>1</sup>

### 2.1. Snímání a digitalizace obrazu

Základem pro zpracování je vlastní získání obrazu a následné převedení do digitální formy. Snímání je převod optické veličiny na elektrický signál. Vstupní informací jsou jas z kamery či scanneru. V případě snímání lékařských obrazových dat je to například intenzita rentgenového záření. Digitalizací se převádí analogový signál na signál digitální. Vstupní signál je dále vzorkován a kvantován a jeho výsledkem je matice čísel popisující digitální obraz [2].

Pro účely této práce byly poskytnuty snímky pořízené fotoaparátem, které vznikly v rámci projektu Visible Human Project. Fotografie zachycují plátky lidského kadáveru (obr. č. 2).



Obrázek 2 - Fotografie z projektu Visible Human Project

---

Převzato z: [http://vision.cse.psu.edu/people/chenpingY/media/case\\_15.jpg](http://vision.cse.psu.edu/people/chenpingY/media/case_15.jpg),  
[http://fmri.mchmi.com/images/fMRI3\\_2.JPG](http://fmri.mchmi.com/images/fMRI3_2.JPG)



## 2.2. Předzpracování obrazu

Po dokončení snímání a následné digitalizace je k dispozici obraz, který může být zkreslen způsobem snímání nebo nevhodnými podmínkami. Chyby lze opravit pomocí korekcí, pokud je známý charakter deformace. Existují také metody předzpracování obrazu, které usnadní analýzu obsahu obrazu, identifikují objekty nebo zvýrazní důležité rysy. Mezi metody patří jasové transformace, geometrické transformace, filtrace a ostření. Další jsou například metody matematické morfologie [2].

Předzpracování obrazu nebude součástí vypracování praktické části, jelikož obrazová data, která budou použita pro analýzu obrazu, jsou v dostatečné kvalitě.

## 2.3. Obrazová segmentace

Tato část zpracování obrazu bývá klíčovou součástí analýzy obsahu obrazových dat. Principem je rozdělení obrazu na různé objekty či oblasti [1]. Výsledkem může být kompletní segmentace obsahující nepřekrývající se oblasti korespondující s objekty na vstupním obraze, jenž odpovídá obrazu reálného světa nebo částečná segmentace, kde vytvořené segmenty nemusí přímo souhlasit s objekty v obraze [3].

Pro kompletní segmentaci je nezbytná spolupráce s vyšší úrovní zpracování, v níž se využívá konkrétních znalostí řešeného problému. Je velmi důležitá pro 3D modelování objektů. U částečné segmentace je výsledkem rozdělení obrazu do samostatných částí, které jsou homogenní vzhledem k určitým vlastnostem (např. jas, barva, textura). Oblasti se obecně mohou překrývat. Na data popisující částečnou segmentaci je nezbytné aplikovat další postupy, které pomocí vyšší úrovně umožní získat výslednou segmentaci [3].

Proces rozdělení obrazu mohou komplikovat následující aspekty. Prvním je samotné pořízení obrazové informace. Data mohou být deformovaná šumem či nehomogenním osvětlením. Dalším jsou složité objekty, u nichž se hranice mohou překrývat. Pro lidské oko může být velmi obtížné rozlišit jednotlivé objekty, obzvláště pro počítačové nástroje. Tyto obtíže se odstraňují při předzpracování obrazu [2].

### **3. Segmentace medicínských obrazových dat**

Medicínská obrazová data je možné získat různými zobrazovacími metodami, buďto z člověka živého nebo z lidského kadáveru. V prvním případě se dají pomocí ultrazvuku, rentgenového záření, počítačové tomografie nebo z histologického snímku pořídit 2D obrazová data. Další možností je použít záznam z kamery (kolonoskopie). 3D obrazová data se získávají především z počítačové tomografie nebo z magnetické resonance.

Používá-li se počítačová tomografie, člověk dostává do těla určité množství zdraví škodlivého záření. Čím vyšší dávka je, tím je umožněno dojít k vyšší kvalitě výstupních dat (větší kontrast snímků, více řezů, ...). Příliš vysoká dávka je ale ze zdravotního hlediska velmi riskantní. Vzniká mnoho spekulací, jak vysoké riziko ionizující záření představuje. Obecně se tedy dávka minimalizuje. Magnetické resonance zmíněná nebezpečí eliminuje. Čím větší je požadované rozlišení u tohoto postupu, tím se doba vyšetření v přístroji prodlužuje.

Ve druhém případě se 2D obrazy pořizují vyfotografováním plátků lidského kadáveru nebo stejnými způsoby jako u člověka živého. K získání 3D dat se opět využívá magnetická resonance a počítačová tomografie. U těchto postupů již není nutné brát v potaz zdravotní limity nebo délku vyšetření, je tedy umožněno dojít k vyšší kvalitě výstupních dat.

Segmentace medicínských snímků má za cíl rozlišit jednotlivé orgány, kosti nebo tkáně, které se na snímku pořízeném některou ze zobrazovacích technik vyskytují. Ze segmentovaných obrazových dat jsou poté vytvářeny trojrozměrné povrchové modely. Velmi velkou výhodou je, že lékař nabyde lepší představy o anatomii. Mimo jiné mohou 3D modely posloužit k tvorbě reálných modelů, které se využívají pro plánování složitých operací nebo pro přípravu umělých náhrad [1].

#### **3.1. Zobrazovací metody (medical imaging)**

Mezi lékařské zobrazovací systémy patří počítačová tomografie, magnetická resonance a další.

### **3.1.1. Počítačová tomografie (computed tomography CT)**

Počítačová tomografie je metoda založená na rentgenovém záření, kde jednotlivé paprsky procházejí lidským tělem různými směry. Měří se přesná absorpce rentgenového průniku vyšetřovaným objektem. Pomocí počítače je obrazový pixel složen z několika měření v odlišných směrech. Typy tkání se určují rozličnými hodnotami intenzity. CT poskytuje tkáňovou hustotu v příčném řezu organizmem. Z původně dvojrozměrného obrazu vytvoří trojrozměrné zobrazení [4].

### **3.1.2. Magnetická resonance (magnetic resonance imaging MRI)**

Magnetická resonance spočívá v distribuci a chování magnetických momentů určitých izotopů v magnetickém poli. Poskytuje informace o chemických a biologických procesech. Rozdíl oproti počítačové tomografii spočívá ve fyzikální podstatě měření. Magnetická resonance udává data o chemické povaze tkání. Používá se převážně pro vyšetření měkkých tkání k nalezení patologických změn, například k objevení zhoubných nádorů [4].

### **3.1.3. Visible Human Project**

Medicínská obrazová data mohou být získávána nejen standartními zobrazovacími metodami, ale také průřezy lidským kadáverem. V rámci projektu Visible Human Project byla vytvořena datová sada obsahující fotografie jednotlivých průřezů. Projekt byl založen institucí National Library of Medicine v USA v roce 1991 [5].

Cílem bylo získat obrazová data padesáti devíti leté ženy a třiceti devíti letého muže. Nejprve byla data pořízena metodou CT a MRI a dále byly pomocí speciálního zařízení vytvořeny jednotlivé průřezy kadáverem, které byly vyfotografovány [5].

Výhodou tohoto přístupu je získání barevných dat s vysokým rozlišením a téměř žádnou deformací [5].


## **3.2. Přístupy k segmentaci obrazových dat**

Cílem segmentace je identifikace objektů v obrazových datech. Objekt lze prezentovat buď svou hranicí, nebo svým objemem. Mezi těmito prezentacemi lze v případě potřeby přecházet. Některé aplikace vyžadují hraniční, jiné naopak objemovou. Výhoda hraniční

bývá v tom, že je paměťově úspornější, ale ztrácí se informace o tom, co se nachází uvnitř.


Třídění na základě charakteru zpracovávaných dat:

- 2D obrazové algoritmy – zpracovávají dvourozměrná rastrová data. 2D segmentace (obr. č. 3) detekuje objekty či oblasti na konkrétním snímku. Algoritmy jsou využívány například při rozboru krve. Identifikují se jednotlivé pixely, které odpovídají krvinkám. Poté se objekty kvantifikují. Mimo jiné je možné pomocí 2D segmentace diagnostikovat z histologického snímku histologický nález [1].




Obrázek 3 - 2D segmentace

- 3D obrazové algoritmy – pracují s 3D rastrovými daty a identifikují objekt reálného světa. 3D segmentace probíhá následujícími způsoby:
  1. Obrazová data z magnetické resonance nebo z počítačové tomografie lze zpracovávat metodami Marching Cubes (obr. č. 4) či Marching Tetrahedra. U algoritmů je vstupem objem dat a konstanta pro práh. Výstupem je hraniční prezentace, síť trojúhelníků. Nevýhodou algoritmu Marching Cubes je vysoký počet trojúhelníků. Další nevýhodou je, že se způsob triangulace povrchu určuje na základě hodnot osmi vrcholů tvořících krychli bez ohledu na její okolí, proto se vyskytují nejednoznačné případy, kudy povrch prochází. To má za následek, že výsledná síť trojúhelníků obsahuje různé artefakty, například místa s dírou, které způsobují nemalé problémy při dalším zpracování. O zamezení nejednoznačností se pokouší algoritmus Marching Tetrahedra. Krychle se rozdělí na pět čtyřstěnů a trojúhelníky se umísťují do nich. Algoritmus se ale příliš často nepoužívá z důvodu vysokého nárůstu počtu trojúhelníků. V případě použití těchto metod je nutné mít velmi kvalitní obrazová data [6].



Obrázek 4 - 3D povrchový model kosti os femoris, vpravo se zvýrazněnou sítí trojúhelníků, kterou je model tvořen.

2. Pro 3D modelování se využívá také 2D segmentace, která se provádí řez po řezu. Nevýhodou je časová náročnost pro uživatele v případě vysokého počtu snímků. Tento způsob je vhodný pro segmentaci cév [6].
3. Další možností je opět provádět segmentaci řez po řezu, ale s tím rozdílem, že kromě prvního řezu se v dalších zohledňují výsledky z předchozích segmentací. Tento způsob využívá například metoda aktivních kontur (popsaná v kapitole 2.2.1), jenž je založena na šablonách [6].
4. V případě, je-li segmentace založená na hraniční prezentaci, využívá se dvou paralelních řezů na dvou koncích objektu (obr. č. 5). Plášť mezi nimi je tvořen automaticky natažením hladkého plátu (parametrické funkce). Tento řez vytvoří segmentaci, kterou si uživatel může upravit, je-li mimo jeho představu. Způsob je vhodný pro podlouhlé hladké objekty, například orgány, u kterých se segmentuje podstatně méně řezů [6].



Obrázek 5 - 3D model rectus femoris dexter vytvořený paralelními řezy

5. Další možností je 3D segmentace pomocí ortogonálních řezů. Nejprve se provede segmentace ve třech rovinách, dle kartézských souřadnic pod-

le rovin  $xy$ ,  $yz$  a  $xz$ , na které se následně natáhne hladký povrch. Uživatel si může segmentaci zkontrolovat a opravit případné chyby. Způsob je obdobný jako čtvrtý, ale díky využití ortogonálních řezů nedojde k oříznutí konců a objekty nemusí být podlouhlé. Tento způsob i způsob čtvrtý lze kombinovat s metodou aktivních kontur, kdy mezi uživatelskou úpravou jednoho řezu a dalšího proběhne několik iterací algoritmu za účelem eliminace počtu uživatelských interakcí [6].

Členění segmentace podle přístupu uživatele:

- Manuální – manuální rozdělení obrazu na oblasti zájmu. Nevýhodou tohoto přístupu může být rozsah zpracovávaných dat z důvodů uživatelské časové náročnosti. Naopak výhodou je, že si uživatel sám určí oblasti, které budou segmentovány. Výsledky jsou poté závislé na přesnosti uživatele a na jeho znalostech [1].
- Interaktivní – spolupráce uživatele s automatickým segmentačním algoritmem. Uživatel inicializuje metody, kontroluje správnost výsledků a provádí případné opravy. Interaktivní metoda se používá například u segmentace medicínských obrazových dat, protože je zde možnost oprav a kontrola výsledků uživatelem [1].
- Automatický – zaměřuje se na automatickou extrakci hranic bez zapojení uživatele. Přístup se používá pro segmentaci, kde jsou výrazně vymezeny objekty. V případě, že hranice objektů nejsou zřetelné, segmentace není přesná [1].

Dělení segmentačních algoritmů:

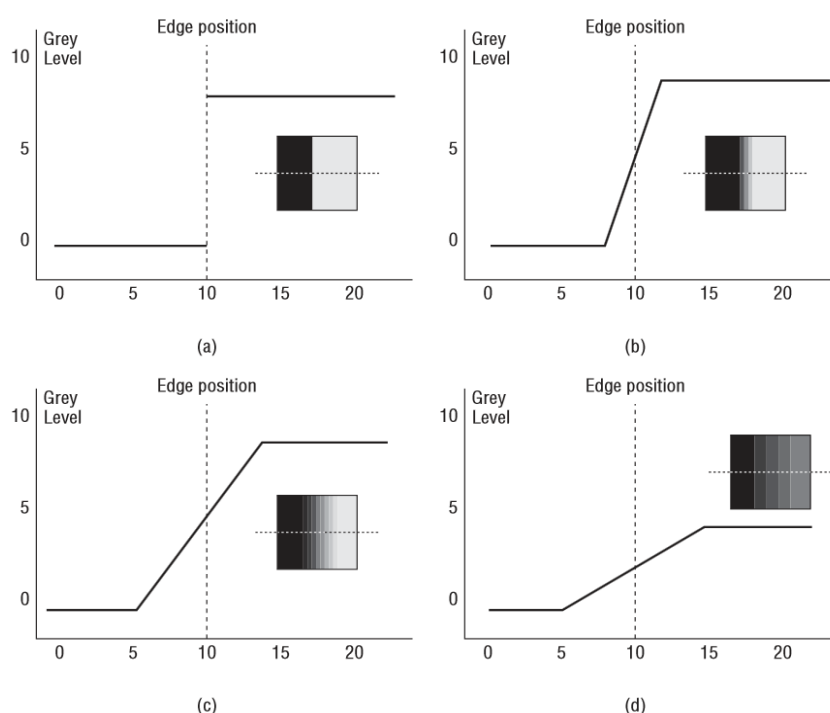
- metody vycházející z detekce hran,
- metody orientované na regiony v obraze,
- statistické metody,
- hybridní metody a znalostní metody.

### **3.2.1. Metody vycházející z detekce hran (edge-based)**

Metody vycházející z detekce hran jsou nejvíce zastoupené a používané v obrazové analýze. Důvodem je, že hrany tvoří obrysy objektů. Hrana je hranice mezi objektem a pozadím nebo indikuje hranice mezi překrývajícími se objekty [7].


Proces detekce hran lze rozdělit do fází: filtrování, diferenciaci a detekce. Filtrování má za úkol částečně nebo zcela odstranit šum z obrazu, který vzniká při pořizování obrazových dat. Diferenciace má za úkol zvýraznit oblasti, u kterých je změna intenzity jasu významná. Samotná detekce identifikuje body, u kterých je změna intenzity nejvýznamnější a určí hrany [1].

Určení hrany je znázorněno na obr. č. 6. Hrana se detekuje změnou úrovně šedé. Čím větší je přechod, tím je identifikace jednodušší. Na grafu (a) je skok největší, tudíž je hrana jednoznačná. Naopak na grafu (d) je přechod šedi pozvolný a je složitější hranu určit [7].



Obrázek 6 - Určování hrany [7]

V případě přesné identifikace je možné určit základní vlastnosti jako je umístění, obvod nebo tvar. Obr. č. 7 znázorňuje detekci objektů. Na obrázku (b) jsou pouze objekty, u kterých jsou určeny hranice. Nelze zde zjistit, které části obrazu jsou objekty a které pozadí. Na druhém obrázku (a) jsou různé odstíny šedi. Pomocí barevných úrovní se dá určit, že objekt „3“ překrývá objekt „2“ [7].



Obrázek 7 - Identifikace objektů [7]

### 3.2.1.1. Hranové detektory

Operátor, který detekuje změny v úrovni šedé, se nazývá hranový detektor. Hranových detektorů existuje velké množství. Každý má své klady i zápory a žádný není univerzální [7].

Základní hranové detektory lze rozdělit do dvou skupin. V první jsou metody, které využívají první derivaci, v druhé skupině se používá druhá derivace. V případě použití první derivace je výsledný hranový gradient porovnán s prahem, jenž určuje, zda se jedná o hrany. Nevýhodou tohoto operátoru je velká závislost na velikosti objektu v obraze a citlivost na šum. Metody druhé derivace detekují hranu na základě prostorové změny v polaritě. Nevýhodou metod druhé derivace je příliš velké vyhlazení obrazu a možná ztráta ostrých rohů [1].

Mezi další hranové detektory patří například hranový detektor založený na předloze, kde se používá diskretní šablona jako model hrany [1] nebo Marr-Hildrethův hranový detektor, Cannyho hranový detektor či Shen-Castanův (ISEF) hranový detektor. Tyto metody popisují hrany s větší přesností, avšak jsou výpočetně mnohem náročnější. Jednotlivé postupy výpočtů popsal J. R. Parker v knize *Algorithms for Image Processing and Computer Vision* [7].

Princip hranového detektoru je vysvětlen na nejjednodušším operátoru. Využívají se zde parciální derivace, které respektují princip os  $x$  a  $y$ . Následuje výpočet gradientu, pokud je obraz chápán jako funkce dvou proměnných [7].

Výpočet gradientu:



$$\nabla A(x, y) = \left( \frac{\partial A}{\partial x}, \frac{\partial A}{\partial y} \right) \quad (2.1)$$

Je zřejmé, že obraz není funkce. Derivace se získá jako rozdíl okolních pixelů obrazu. Protože je obraz diskrétní, používá se derivace, která je aproximována rozdíly v šedých úrovních. V tomto případě se předpokládá, že se mezi pixely úrovně šedi mění lineárně [7].

Nejjednodušší aproximace:

$$\nabla_{x1} A(x, y) = A(x, y) - A(x - 1, y) \quad (2.2)$$

$$\nabla_{y1} A(x, y) = A(x, y) - A(x, y - 1) \quad (2.3)$$

V této aproximaci nastává problém, je-li potřeba vypočítat gradient v bodě  $(x - \frac{1}{2}, y - \frac{1}{2})$ . Hranice bude posunuta o půl pixelu ve směru  $-x$  a  $-y$ . Lepší volba aproximace je následující:

$$\nabla_{x2} A = A(x + 1, y) - A(x - 1, y) \quad (2.4)$$

$$\nabla_{y2} A = A(x, y + 1) - A(x, y - 1) \quad (2.5)$$

Tento operátor se používá k výpočtu gradientu. Výsledný vektor obsahuje informace o tom, jak silná hrana je a jaký má směr. Velikost vektoru je délka přepony pravoúhlého trojúhelníku, jenž odráží sílu hrany nebo hranovou odezvu v daném pixelu. Směr hrany v tomto pixelu je úhel, který svírá přepona s osou [7].

Matematicky je hranová odezva dána vztahem:

$$G_{mag} = \sqrt{\left(\frac{\partial A}{\partial x}\right)^2 + \left(\frac{\partial A}{\partial y}\right)^2} \quad (2.5)$$

Směr hrany:

$$G_{dir} = \text{atan} \left[ \frac{\frac{\partial A}{\partial y}}{\frac{\partial A}{\partial x}} \right] \quad (2.6)$$


Velikost hrany bude reálné číslo, obvykle se zaokrouhluje na číslo celé. Každý pixel, který převýšil specifickou prahovou hodnotu, je klasifikován jako hranový bod [7].

### 3.2.1.2. Aktivní kontury (Active Contours – „Snakes“)

Další metodou pro detekci hran jsou aktivní kontury. Aktivní kontura je křivka definována uvnitř obrazu, která se může pohybovat pod vlivem interních sil, definovaných samotnou křivkou, a vnějších sil vypočtených z obrazových dat. Vnitřní a vnější síly jsou definovány tak, že se kontury přizpůsobí hranám nebo jiným obrazovým vlastnostem [8].

Existují různé formy modelů aktivních kontur, mezi nejzákladnější patří hadí aktivní kontury. Nevýhodou standardního algoritmu je, že při složité struktuře objektu kontura neodpovídá jeho hranici. Tento problém se snaží vyřešit jiné metody, které jsou ovšem algoritmicky náročnější.

Rozšíření a vylepšení běžné hadí metody o shlukování a vyhlazení zpracovali Juan Xu, Opas Chutatape a Paul Chew [9]. Další metody jsou například parametrické aktivní kontury vázané a nevázané popsané Christopherem Zimmerem ve vědeckém článku Coupled Parametric Active Contours [10] či geodesické aktivní kontury popsané v článku Fast Geodesic Active Contours [11]. Upravené metody jsou vhodné i pro detekci složitějších objektů a umožňují počáteční inicializaci parametrů, které následně ovlivňují výsledný tvar kontury. Obr. č. 8 znázorňuje použití metod [1].



Obrázek 8 - Metoda aktivních kontur [2]

Na hadích aktivních konturách (Snake Active Contours) je demonstrována základní myšlenka. Model hadích aktivních kontur je popsán jako řízená kontinuita modelu ovlivňována různými silami. Interní síly mají vliv na ohyby charakteristické pro linii, zatímco obrazové síly jako například gradient slouží k přilnutí kontury na obrazové prvky. Je-li aktivní kontura (vektor) definována parametricky  $v(s) = (x(s), y(x))$ , celková energie je definována jako

$$E_{snake}^* = \int_0^1 E_{snake}(v(s))ds = \int_0^1 E_{int}(v(s))ds + \int_0^1 E_{image}(v(s))ds \quad (2.7)$$

$E_{int}$  jsou vnitřní síly,  $E_{image}$  obrazové síly [8].

Interní síla je definována jako

$$E_{int} = (\alpha(s)|v_s(s)|^2 + (\beta(s)|v_{ss}(s)|^2)/2 \quad (2.8)$$

$v_s$  je první prostorová derivace souřadnic a  $v_{ss}$  druhá. První část vzorce reprezentuje elasticitu a druhá pevnost. Koeficienty  $\alpha$ ,  $\beta$  mohou být použity ke kontrole kontinuity křivky. Ovlivňují pružnost a pevnost křivky. Nastaví-li se  $\beta(s)$  na nulu v konkrétním bodě, vytvoří se v tomto bodě roh [8].

Obrazové síly jsou složeny ze tří různých energických funkcionalů. Konkrétně ze sil, jež se přimykají k linii, hraně a zakončení. Síly jsou definovány jako

$$E_{image} = w_{line} E_{line} + w_{edge} E_{edge} + w_{term} E_{term} \quad (2.9)$$

$w$  jsou váhy, které se zadávají empiricky pro zadaný typ problému [8].

Kompletně je tato metoda představena v článku [8] autory M. Kass, A. Witkin a D. Terzopoulos. Hledání optimálních křivek ve smyslu minimálních energií je úloha známá z fyziky. Eulerovy rovnice a variační počet patří mezi základní prostředky k jejich řešení [8].

### 3.2.1.3. LiveWire, IsoSurface

Mezi další metody vycházející z detekce hran patří například LiveWire algoritmus či IsoSurface.

LiveWire algoritmus nalézá cesty s nejnižšími náklady například podle Dijkstrova algoritmu z jednoho bodu do druhého. Výsledkem je „graf“, kde pixely znázorňují uzly, a hrany jsou přechody mezi pixely. Algoritmus se používá u interaktivní segmentace. Kontury, které vytváří uživatel, se automaticky přichytávají k hranicím objektů [12].

Algoritmus IsoSurface se velmi často používá pro rekonstrukci trojrozměrných povrchových modelů ze vstupních objemových diskrétních dat, které se nejčastěji získávají

metodou Marching Cubes. Povrch modelu se vytváří propojením voxelů, jejichž intenzita je rovna definované hodnotě tzv. iso hodnotě. Jsou-li data deformována šumem, velmi často dochází ke vzniku nežádoucích artefaktů, jenž je možno odstranit optimalizací modelu, například vyhlazením [2].

### **3.2.2. Metody orientované na regiony v obraze (region-based)**

Metody detekují namísto hranic přímo oblasti v daných obrazových datech. Region je definován jako prostorově spojitá množina pixelů. Hlavním segmentačním kritériem u těchto přístupů je homogenita oblasti například úrovně šedi, textury, tvaru či barvy. Proces spočívá v rozdělení heterogenních regionů na segmenty, které jsou homogenní. Tato metoda oproti hranové detekci je výhodnější v případě, že je obraz zatížen šumem. Hrany jsou poté těžce rozeznatelné [1].

V rámci segmentace jsou nejprve vytvořeny atomické oblasti pomocí kvantizovaných hodnot pixelů. V následujícím kroku jsou oblasti spojovány do větších celků, jsou-li splněna definovaná kritéria. Jednotlivé metody se mohou lišit pravidly pro počáteční rozdělení oblastí i kritérii pro jejich následné spojování. Výsledek spojování je též závislý na pořadí, v jakém jsou oblasti spojovány [1].

Mezi nejjednodušší techniky patří metoda narůstání oblastí (Region Growing) [2]. K dalším metodám se například řadí algoritmus, který je představen v článku *Seeded Region Growing (SRG)* [13] od R. Adamse a L. Bischa. Metoda vyžaduje vstup množiny semen buď jednotlivých pixelů, nebo skupin pixelů, které kontrolují tvorbu nových regionů. Používá automatizované postupy nebo ruční výběr semen. SRG je metoda založená na narůstání oblastí dle podobnosti pixelů v rámci regionu, ale mechanismus zahrnuje i metodu watershed, která je popsána v kapitole 2.2.4. SRG je řízena volbou (obvykle malou) obrazových bodů, které jsou známé jako semena [13].


### **3.2.3. Statistické metody**

U tohoto přístupu existuje mnoho metod, které jsou založené na empirických datech. Mezi metody patří například prahování, shluková analýza či fuzzy connectedness.

Prahování (thresholding) spočívá v jednoduchém principu převedení intensity pixelu na binární hodnotu. Poté je vytvořen histogram, na základě kterého se určí jednotlivé prahy, podle nichž je obraz rozdělen. Výsledkem je binární obraz, který obsahuje dva

typy pixelů 0- není objekt, 1- je objekt. Prahování je vhodná metoda v případě, že se objekty nedotýkají a hodnoty jejich jasu jsou oddělitelné od hodnot pozadí. Ukázka prahování je na obr. č. 9. Nevýhodou histogramů je, že neobsahují prostorové informace o pixelech, takže obraz složený ze dvou obdélníků, bílého a černého, bude mít stejný histogram jako obraz složený s náhodně roztroušenými černými a bílými tečkami [1].

Prahování obdobně jako metoda narůstání oblastí jsou algoritmy, které bývají obvykle zahrnuty v procesech analýzy obrazových dat, zejména pro detekování malých a jednoduchých struktur jako jsou nádory či léze tkání [13].



*Obrázek 9 - Metoda prahování*

Další metodou je shluková analýza. Cílem je sdružit data s podobnými vlastnostmi do shluků na základě měření prováděných pro jednotlivé pixely tak, že podobnost členů v jednom shluku je maximální, naopak podobnost s členy mimo tento shluk je minimální [1].

Metoda je snadno rozšířitelná a modifikovatelná, ale stejně tak jako algoritmus narůstání oblastí je závislá na počátečním nastavení. V tomto případě se namísto semen vybírají první shluky. Shlukování ale nelze přímo začlenit do metod prostorového modelování, protože je velmi citlivé například na šum v obraze [14].

Fuzzy connectedness. je metoda s „fuzzy“ přístupem, která spočívá v podobnosti objektů v obraze. Podobnost se může počítat jako váhová suma intenzit a obrazových derivací v okolí pixelu. Jelikož jsou váhy okolních pixelů předem dané, výsledná segmentace je citlivá na zvolené váhy a vlastnosti regionů v obraze [2].

### 3.2.4. Hybridní metody

Zde jsou uvedené metody, které využívají některé prvky z metod výše zmíněných. Do hybridních metod spadá například metoda záplavové transformace [15] nebo metody založené na algoritmu neuronových sítí [16]. Používají se například při segmentaci bílé a šedé mozkové kúry.

Základ metody záplavové transformace (watershed transform) vychází z geografie. Obraz je chápán jako topografický reliéf, který je kódován vodou. Jedním z přístupů je představit si, že krajina, kde jsou lokální minima, je jezero. Oproti metodám, které využívají neuronové sítě, je zde nevýhodou citlivost na šum. Když je obraz zatížen šumem, je technika prakticky nepoužitelná [15].

Neuronová síť má za vzor činnost lidského mozku, kde základem je neuron. To samé platí i pro softwarové neuronové sítě. Jednotlivé neurony jsou propojeny hranami, které jsou ohodnoceny. Hlavní předností neuronové sítě je schopnost učit se, tedy zapamatovat si kombinace, které vedou k požadovanému výstupu a u nových vstupů se poté obrátit na „svou“ paměť. Na základě zkušeností se odhadují nové výsledky. Používají se přístupy učení s učitelem a učení bez učitele. Učení s učitelem využívá zpětné vazby. Je předložen vzor, jenž se porovná s aktuálním výsledkem a určí se chyby, které se opraví a tím se docílí se minimální chybovosti. Výhodou je interakce uživatele, který má možnost provést korekce. V případě použití metody učení bez učitele se výstup uživatelem nevyhodnocuje [16].

V literatuře se nalezne mnoho algoritmů s učitelem i bez učitele. Jejich kombinací je například metoda GRBF (Generalized Radial Basic Function) neuronové sítě, které spojují výhody obou přístupů. Algoritmus zahrnuje i některé nedostatky jako například obtížné zhodnocení kvality segmentace nebo ruční anotace trénovacích dat [1].

### 3.2.5. Znalostní (knowledge-based)

Do této kategorie spadají algoritmy, jež využívají již dříve získaných znalostí o objektech, které se v obraze vyskytují. Jsou použity šablony či modely, které se porovnávají s obrazem a hledají se případné shody. Metody založené na znalostech jsou nevýhodné při segmentaci složitých struktur s různou variabilitou. Pokud je ale struktura ve všech případech podobná, jsou tyto metody velmi výhodné [1].

### **3.2.6. Souhrn metod**

Jak je z výše uvedeného popisu patrné, metod pro segmentaci medicínských obrazových dat existuje velké množství. Je to především z důvodů, že žádná není univerzální a nelze ji použít pro všechny typy snímků. Například metody detekce hran jsou špatně použitelné na obrazy zatížené šumem. S tímto problémem se vypořádají metody narůstání oblastí, ale jsou spíše uplatňované pro segmentaci malých a jednoduchých struktur. Obdobně tak jako metoda prahování. Algoritmy založené na neuronových sítích se dají velmi dobře využít pro segmentaci spletitých struktur, ale jsou velmi složité na implementaci. Metodu záplavové transformace lze také využít k segmentaci složitých struktur, ale je nepoužitelná pro snímky deformované šumem.

## 4. Nástroje pro segmentaci medicínských obrazových dat

Mnohé z metod pro zpracování digitálního obrazu, které jsou uvedené v předchozí kapitole, jsou implementovány v běžně dostupných nástrojích. V této kapitole jsou vybrány nástroje, které splňují podmínky pro vypracování 3D modelu. Je zde provedeno jejich srovnání, které se zaměřuje nejen na uživatelskou náročnost, ale také na použité techniky segmentace.

### 4.1. MeVisLab

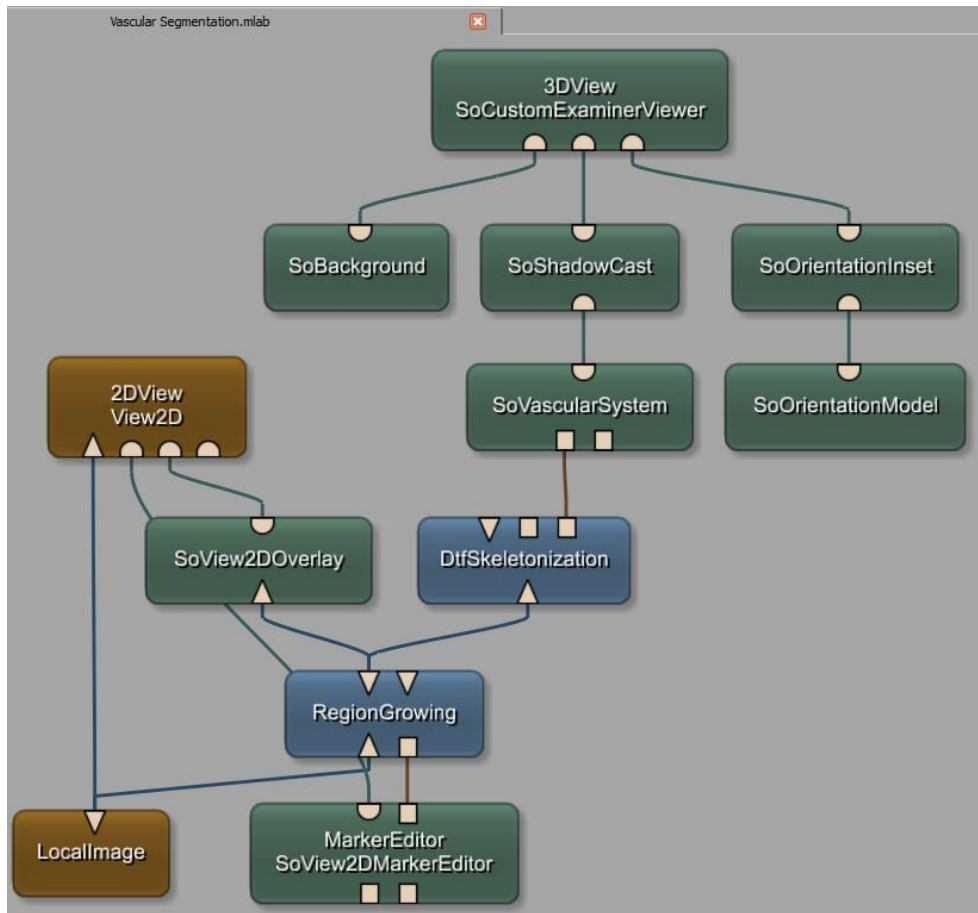
MeVisLab je nástroj pro zpracování medicínských obrazových dat a vizualizaci stavebních bloků, které lze kombinovat a vytvářet tak nové algoritmy a prototypové aplikace. Nástroj má k dispozici rozsáhlé knihovny funkčních komponent, dále pokročilé softwarové moduly pro segmentaci, registraci, volumetrii a jiné. Program nabízí vizuální prezentaci medicínských dat a to jak 2D interaktivní, tak 3D interaktivní. Vývojové prostředí MeVisLab je k dispozici ve dvou různých verzích z oficiálních stránek <http://www.mevislab.de/>. První verze je plná a druhá omezená a neregistrovaná. Licenční podmínky pro obě verze se liší pro komerční a nekomerční použití. Instalace MeVisLab SDK Unregistred bez licenčních souborů je bezplatná, ale má omezenou funkčnost, například ve vytváření vlastních modulů. Pro účely této práce není potřeba placené verze [17], [18].

Zásadní částí programu je knihovna Mevis Image Processing Library (ML), která poskytuje obecný rámec pro zpracování obrazu. V současné době existuje přes pět tisíc modulů, které jsou pro zpracování obrazu k dispozici. Mezi moduly patří například různé metody filtrace, segmentace, transformace obrazu nebo statistické analýzy. Navíc jsou přístupné moduly založené na Insight ToolKit (ITK) a Visualization ToolKit (VTK). MeVisLab poskytuje podporu pro práci s obrazy uloženými ve formátu DICOM, JPEG, BMP, PNG, TIFF a jiných [18].

Nástroj umožňuje z jednotlivých modulů vytvořit program, jenž implementuje kompletní zpracování a vizualizaci obrazu. MeVisLab využívá grafický programovací přístup, kde uživatelí umožní instanci modulů a definici toku dat zakreslením vztahů mezi jednotlivými moduly (obr. č. 10). Dále je umožněné definovat makra, pro která je nezbytná znalost jazyka Python nebo JavaScript. Pro vývoj modulů je nutné ovládat programova-



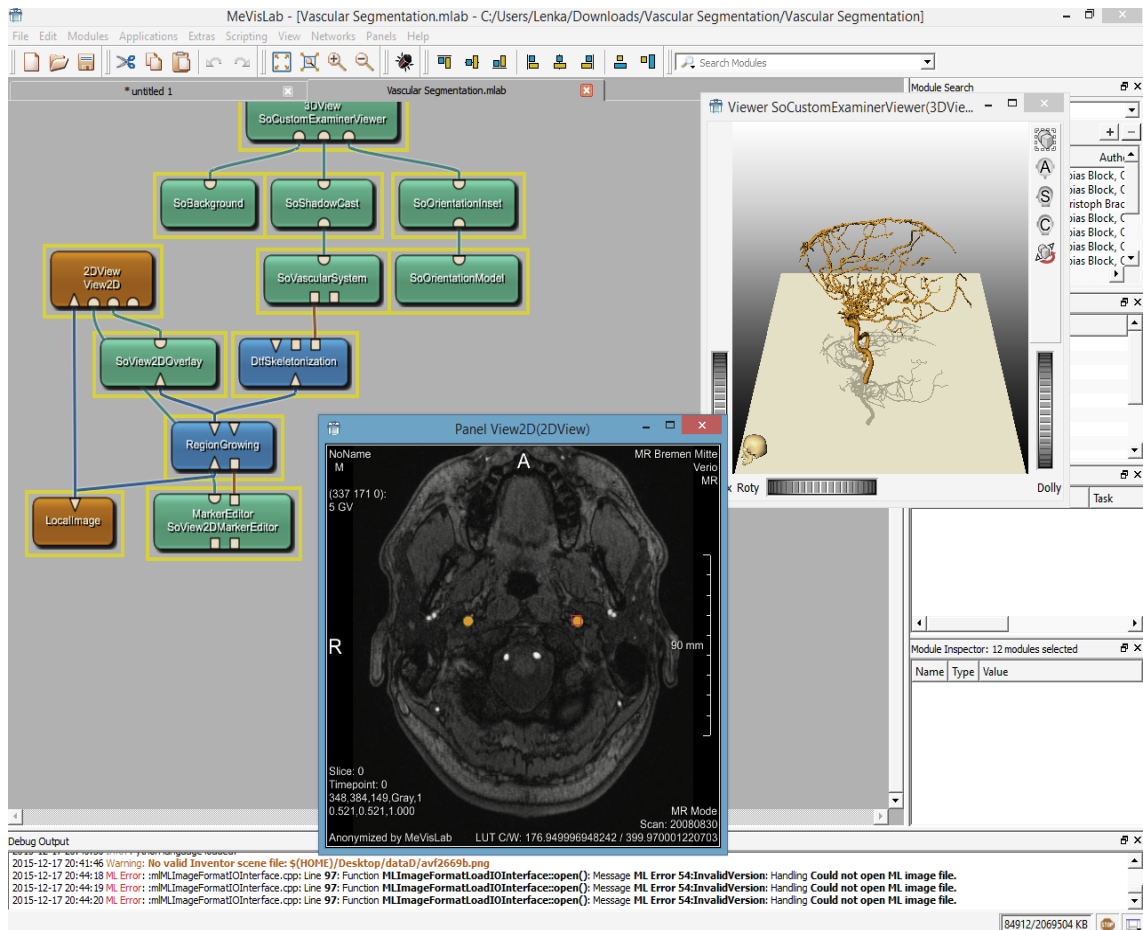
cí jazyk C++. K vizualizaci musí mít uživatel povědomí o zpracování obrazu a o počítačové grafice [18].



Obrázek 10 – Algoritmus v nástroji MeVisLab

Moduly, které jsou určeny k segmentaci, používají následující segmentační algoritmy: metodu aktivních kontur, LiveWire, narůstání oblastí, prahování či fuzzy connectedness. Metody a algoritmy jsou popsány v kapitole 2.2.

Nástroj je uživatelsky náročnější z důvodů tvoření algoritmů z jednotlivých modulů, ale na druhou stranu umožňuje velký počet možností, jak z obrazových dat vytvořit 3D model. Po naprogramování algoritmu a načtení vstupních dat se vyznačí hranice objektu dle zvolené metody. Vyznačení se automaticky aplikuje na další snímky a proběhne modifikace na konkrétní obrys objektu. Následně se vygeneruje 3D model (obr. č. 11).



Obrázek 11 - MeVisLab

## 4.2. 3D-DOCTOR

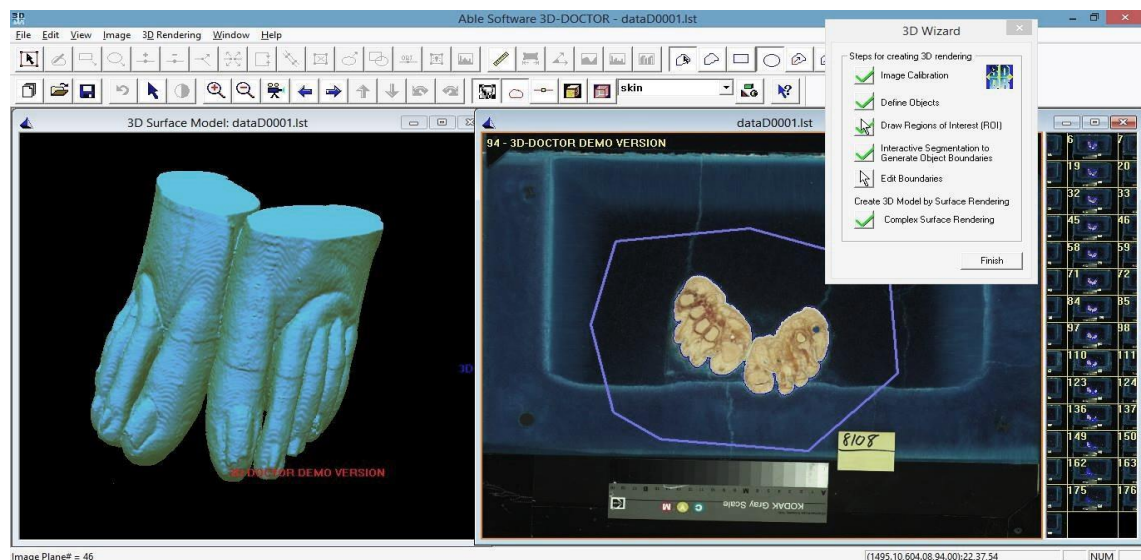
3-D DOCTOR je moderní software pro 3D modelování, měření a zpracování obrazu pro zobrazovací metody jako je například magnetická resonance, počítačová tomografie a jiné. Nástroj je dostupný z <http://www.ablesw.com/3d-doctor/> jako shareware. Zkušební doba je jeden měsíc. Demo verze je plně funkční, až na některé exportní funkce. Cena softwaru pro nekomerční využití se pohybuje okolo 2 400 \$. Program podporuje černobílé i barevné snímky uložené ve formátech DICOM, TIFF, PNG, JPG, BMP a umožňuje export polygonů do STL, DXF, OBJ a jiných formátů [19].

Nástroj nabízí různé přístupy segmentace, mezi které patří plně automatická segmentace, poloautomatická interaktivní segmentace a segmentace objektů používající tréninková data. Automatická segmentace využívá segmentační metody texture-based, která je založená na určení hranic pomocí textur obrazu. Pro extrahování objektů je pouze nutné zadat počet objektů, které mají vytvořit 3D model. Poloautomatická segmentace pracuje s metodou prahování, která je popsána v kapitole 2.2.3. Nejprve se odhadne

optimální práh pomocí histogramu. Uživatel si poté může ideální prahovou hodnotu přenastavit. Program provede segmentaci a získá hranice. Region-based a polygon-based jsou přístupy (viz kapitola 2.2.2), které využívají segmentaci s tréninkovými daty. Uživatel označí region, jehož specifické vlastnosti budou aplikovány na další segmentaci. Metoda se používá k extrakci malých objektů uzavřených ve větších, například pro zobrazení kostí či cév v hlavě [19].

Nástroj je uživatelsky přívětivý. Oficiální stránky nabízejí dokumentaci k programu, ze které je možné vyčíst a z videí zhlédnout vše, co je potřebné. Plně automatická segmentace je vhodná pouze pro snímky, ve kterých jsou jasně viditelné textury. Je možné vybrat si část obrazu, kde bude segmentace provedena. Hranice je možné vypnout a nechat pouze ty, které uživatel potřebuje. V případě, že hranice nejsou zřetelně viditelné, automaticky se vyberou i oblasti, které nemají být součástí modelu. U jednotlivých snímků není možné provést opravy. Interaktivní segmentace spočívá ve vybrání oblasti, která má být segmentována. Po výběru si uživatel nastaví optimální práh. Toto nastavení se automaticky provede i u ostatních snímků. Uživatel si poté může na jednotlivých snímcích prahy měnit.

Nejvhodnější přístup je interaktivní segmentace, u které má uživatel možnost kontrolovat a upravovat vyznačení struktury. Obr. č. 12 znázorňuje vytvořený 3D model kůže vybrané části.



Obrázek 12 – 3-D DOCTOR

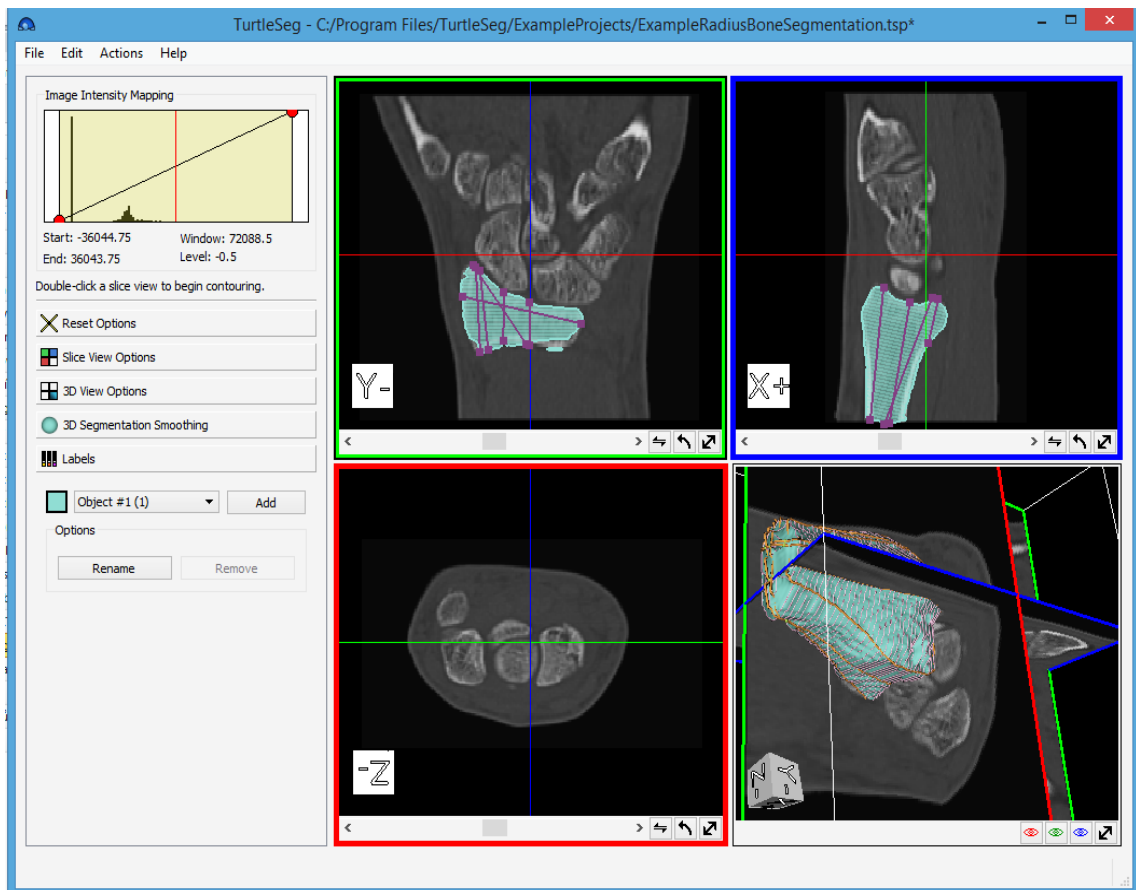
### 4.3. TurtleSeg

TurtleSeg je interaktivní segmentační nástroj pro vytváření 3D modelů, zdarma dostupný z <http://www.turtleseg.org/index.php> pouze jako freeware. Plnou verzi je možné zakoupit, cena se pro nekomerční využití pohybuje okolo 600 \$. V programu je nutná spolupráce uživatele, která spočívá ve vyznačování kontur. Je zde použitý segmentační algoritmus LiveWire [20].

Vstupní data musí být ve formátu DICOM. Pokud má uživatel jiný formát, lze jej převést na DICOM pomocí konvertorů, které jsou běžně dostupné na internetu (např. nástroj Onis, dostupný z <http://www.onis-viewer.com/>).

Prvním krokem před samotnou segmentací je nastavení intensity jasu obrazu tak, aby kontury, které bude chtít uživatel segmentovat, byly co nejvýraznější. Dále uživatel obtáhne objekt, který má být segmentován. LiveWire algoritmus uživateli ulehčí práci tím, že se kontura automaticky přilne k hranici objektu. Pro úplnost modelu je nutné objekt označit na více snímcích. Nástroj po prvním vyznačení kontury u dalších snímků napovídá, jak by měla hranice objektu vypadat. U variabilních objektů není zaručené, že program dle šablony určí hranice správně. Uživatel si může obrysy libovolně upravovat.

Nástroj TurtleSeg je uživatelsky velmi přívětivý, protože obsahuje málo funkcí a uživatel si práci s ním velmi rychle osvojí. Jeho nevýhodou je, že v programu není umožněna automatická segmentace. Metody a postupy jsou vhodné pro segmentaci objektů s výraznými hranicemi, kde se nabízí využít automatický přístup. Další nevýhodou je, že-li objekt malý a špatně rozeznatelný. Pak není možné dojít k uspokojivým výsledkům. Uživatel musí mít apriorní znalost o tom, co segmentuje. V opačném případě by u složitějších struktur mohl vyznačit hranice mimo realitu. Použití nástroje na zkušebních datech zobrazuje obrázek č. 13.



Obrázek 13 – TurtleSeg

#### 4.4. ITK-SNAP

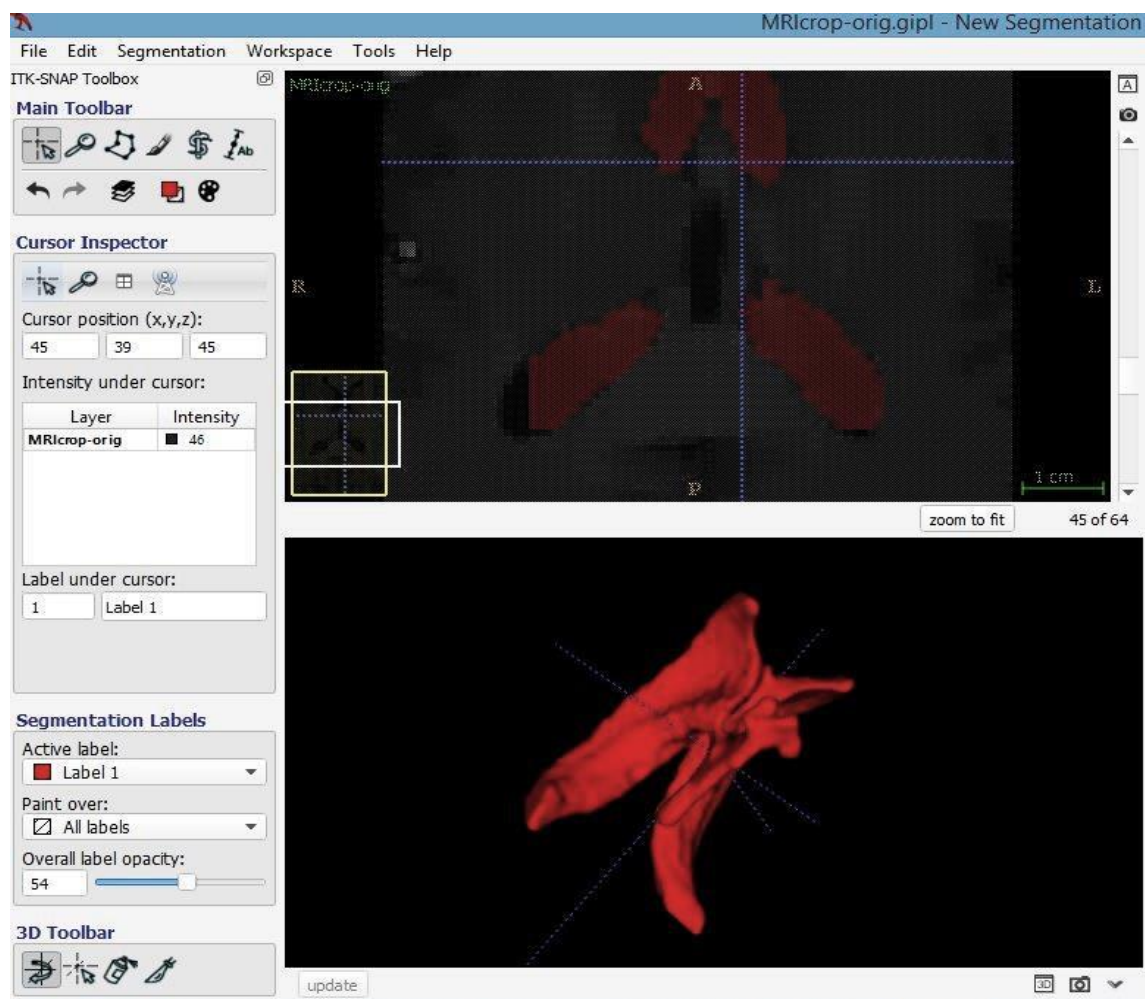
ITK-SNAP je softwarová aplikace sloužící k segmentaci struktur 3D medicínských obrázků. Program je zdarma dostupný z <http://www.itksnap.org/pmwiki/pmwiki.php>. Umožňuje interaktivní či manuální segmentaci. Vstupní data musí být ve formátu DICOM. Pokud má uživatel jiný formát, lze jej převést pomocí různých konvertorů [21].

Interaktivní segmentace se skládá ze čtyř kroků. Prvním je definování oblasti zájmu na vstupním obraze. Další fází je vytvoření nového obrazu nazývaného „speed image“. Speed image nabývá hodnot 1 a -1. Hodnoty, které se blíží k číslu 1, odpovídají požadované struktuře a hodnoty, které se blíží k číslu -1, jsou ostatní části obrazu. Pro tuto fázi jsou k dispozici metody: prahování, klasifikace, shlukování a hranová detekce, které jsou popsány v kapitole 2.2 [21].

Klasifikace je nejpoužívanější metodou v programu. Uživatel vykreslí dvě či více tkání a nástroj na základě příkladů přiřadí hodnoty ostatním částem. Třetím krokem je inicializace semen uvnitř struktury zájmu. Poslední fází je evoluce, ve které se vytvářejí jed-

notlivé souvislé struktury nebo soubory struktur, které jsou závislé na počátečním výběru semen uživatelem [21].

Nástroj ITK-SNAP je uživatelsky velmi přívětivý. Veškeré funkce a metody jsou popsány v dokumentaci, která se nachází na oficiálních stránkách nástroje. Uživatel má možnost vybrat si metodu, která je pro segmentaci dané oblasti nejvhodnější. Výběr oblasti se automaticky aplikuje na všechna data v programu. Nevýhodou může být segmentace složitějších struktur, u kterých nemá uživatel možnost měnit speed image pro jednotlivé obrázky. Použití nástroje na vzorových datech znázorňuje obrázek číslo 14.



Obrázek 14 – ITK-SNAP

## 4.5. Zhodnocení nástrojů

Byly vyzkoušeny čtyři nástroje, které vyhovovaly podmínkám pro segmentaci medicínských dat. Jsou jimi MeVisLab, 3D-DOCTOR, TurtleSeg a ITK-SNAP. Přehled vlast-

ností těchto nástrojů je uveden v tabulce č. 1. Cena za nástroj je uvedena pro nekomerční využití za účelem vytvoření 3D modelu člověka.

Název nástroje	Cena	Rozšiřitelnost	Automatická segmentace	Uživatelská náročnost
<b>MeVisLab</b>	zdarma	Windows, Mac OS, Linux	vyšoká	vyšoká
<b>3D-DOCTOR</b>	58 867 Kč (\$2 400)	Windows	střední	střední
<b>TurtleSeg</b>	14 643 Kč (\$597)	Windows	nížká	nížká
<b>ITK-SNAP</b>	zdarma	Windows, Mac OS, Linux	střední	nížká

*Tabulka 1 – Souhrn vlastností testovaných programů pro segmentaci medicínských dat*

MeVisLab je nástroj, který je uživatelsky náročný. Uživatel se musí orientovat v modulech a mít představu, jak chce segmentaci provádět. Výhodou je možnost velkého výběru segmentačních algoritmů a dalších technik zpracování obrazu.

Další nástroj TurtleSeg funguje na základě spolupráce s uživatelem. Jeho podstatnou nevýhodou jsou použité metody (prahování, LiveWire), které nejsou vhodné pro segmentaci složitých struktur.

Třetí vyzkoušený nástroj byl 3D Doctor. Uživatelsky je velmi přívětivý. Je zde umožněna segmentace manuální, automatická i interaktivní. Nejvíce vyhovující přístup je interaktivní, který pracuje s metodou prahování.

Poslední nástroj, který byl otestován, je ITK-SNAP. Nevýhodou může být segmentace složitých objektů, kdy uživatel nemá možnost měnit speed image pro jednotlivé obrázky a musí použít segmentaci manuální.

Po vyzkoušení funkcí jednotlivých nástrojů byl vyhodnocen jako nejlepší varianta pro vytvoření 3D modelu člověka nástroj MeVisLab. Program obsahuje nejvíce segmentačních přístupů a uživatel může určit postup vytváření modelu. Mimo segmentaci nabízí MeVisLab použití různých druhů filtrů, transformací a dalších technik zpracování obrazu. Program je multiplatformní a zdarma dostupný.




## 5. MeVisLab

V této kapitole je popsán nástroj MeVislab, který byl na základě srovnání s ostatními (viz kapitola 3.5) vyhodnocen pro účely této práce jako nejvhodnější. Vývoj v MeVisLab může být proveden ve třech úrovních. První je vizuální úroveň umožňující zpracování obrazu, vizualizaci a interaktivní práci s moduly, které lze kombinovat pomocí grafického programovacího přístupu. Další úroveň je skriptovací, v níž se vytvářejí makra. Poslední je C++ úroveň, ve které se vyvíjejí nové moduly. Tato práce se bude zabývat pouze první vizuální úrovní [18].

Veškeré informace o nástroji, dokumentace a příklady jsou uvedené na oficiálních stránkách programu <http://www.mevislab.de/> v sekci „About MeVisLab“. V nainstalovaném balíčku nástroje je také přiložena dokumentace. Při spuštění programu se na uvítací obrazovce zobrazí tutoriály, manuály a dokumentace [18].

### 5.1. Moduly




Základní entity, se kterými se v nástroji pracuje, jsou graficky znázorněné moduly vlastnící specifické funkce a algoritmy, určené k vizualizaci a zpracování obrazu. Existují tři základní typy modulů uvedené v tabulce č. 2. U každého modulu je nápověda, která popisuje jeho funkci, parametry a vlastnosti. Mimo jiné je i možné zobrazit příklad algoritmu, ve kterém je konkrétní modul obsažen a tím snadněji pochopit, jak pracuje [18].

Typ	Vzhled
ML moduly (modré)	
Open Inventor (zelené)	
Makro moduly (hnědé)	

Tabulka 2 – Typy modulů MeVisLab

Většina modulů je vybavena konektory. Dolní část představuje vstupy a horní výstupy. Jsou definovány tři typy konektorů, které zobrazuje tabulka č. 3 [18].



Popis	Vzhled
Base objekty: pointery na datové struktury	
ML obrázky	
Inventor scéna	

Tabulka 3 – Typy konektorů MeVisLab

Výstupní konektor jednoho modulu musí být propojen se stejným typem konektoru na vstupu druhého modulu. Spojováním modulů se vytvářejí algoritmy, pomocí kterých je možné realizovat složité úkoly [18].

## 5.2. Moduly určené k načtení dat

MeVisLab primárně pracuje s daty ve formátu DICOM/TIFF. Data ze zobrazovacích metod (např. z magnetické resonance) jsou nejčastěji ukládána ve formátu DICOM, který má pouze jednu komponentu. Standart nepodporuje jiné datové typy než znaménkový a neznaménkový 16 bitový integer. Z důvodů, že data mohou obsahovat více komponent, jsou v MeVisLab ukládána jako (u)int32 v DICOM/TIFF formátu. TIFF soubor obsahuje (u)int32 a DICOM standartní (u)int16 [18].

Mezi moduly, které slouží k načtení dat, patří například *ImageLoad* nebo *LocalImage*. Tyto moduly jsou schopné načíst data vícero formátů. Pro vytvoření 3D modelů je výhodné načíst data ve formátu DICOM, protože obsahuje takzvané tagy a vytváří tak sérii obrázků. Standart DICOM obsahuje mnoho částí, které nemusí být kompatibilní s moduly pro načítání dat. Pokud obsahuje nesprávné hodnoty, data jsou zcela ignorována. Z důvodů, že MeVisLab pracuje primárně s formátem DICOM/TIFF, DICOM série obrázků se u většiny modulů nenačte, ale například modul *DirectDicomImport* je schopen načíst adresář, ve kterém se série DICOM dat nachází. Existují i moduly (*DicomImport*), které převádějí sérii DICOM dat na formát DICOM/TIFF [18].

Práci v nástroji může zkomplikovat velký objem dat. Nahrání i výpočet u celé série obrázků poté trvá desítky minut, i déle. Řešením může být modul *MLImageFormatSave*, který umožňuje data zkomprimovat a uložit do specifického formátu nástroje MeVisLab. Data jsou poté používána knihovnou Mevis Image Processing Library, a tím se, jak uvádí manuál nástroje, časová náročnost jednotlivých výpočtů snižuje [18].

### 5.2.1. Definice oblasti zájmu (ROI - Region Of Interest)

V případě, že nejsou vstupní data oříznuta, lze v nástroji použít modul *ROISelect*, který v datové sadě definuje oblast zájmu. Mimo jiné může sloužit pouze k účelu přiblížení snímku. Definice oblasti zájmu je výhodná při segmentaci struktur uvnitř jiných objektů. V modulu je možné nastavit schéma rozvržení vstupních dat. Definice zájmové oblasti se aplikuje na celou sérii nahraných dat. Nevýhodou je, že tento krok zabere velkou část paměti, kterou má program k dispozici.

## 5.3. Moduly určené k segmentaci dat

Tato podkapitola popisuje jednotlivé moduly určené k segmentaci. Metody a algoritmy jsou popsány v kapitole 2.2. Nejvíce využívané metody jsou narůstání oblastí, prahování, metoda aktivních kontur IsoSurface a LiveWire algoritmus.

Modul *RegionGrowingMacro* nabízí možnost provést segmentaci pomocí metody narůstání oblastí. Zahrnuje veškeré funkce potřebné k vyznačení struktury. V prohlížeči se u jednoho obrázku nastaví počáteční umístění semen. Dále se upravuje prahová hodnota, která narůstání oblastí ovlivňuje. Podstata výpočtu je v umístění semen a v nastavení prahové hodnoty u celé série nahraných obrazových dat.

Modul *Threshold* implementuje metodu prahování. Aplikuje na sérii obrazových dat nadefinovaný práh. Může být určeno, co se stane s voxely, které do prahové hodnoty spadají a těmi, které ne. *IntervalThresh* zpracovává obraz filtrováním, ale pouze pro ty obrazové hodnoty, které leží v určitém prahovém intervalu. Voxely ležící mimo tento rozsah lze nastavit na nulu nebo definovat jinak.

Další možností, jak segmentaci provést, je použít modul *FuzzyCluster*. Modul implementuje fuzzy c-means algoritmus, který klasifikuje celou sérii obrazových dat do různých tříd na základě hodnot šedi. Počet tříd určuje uživatel. Voxely nabydou hodnoty v rozmezí od 0 do 1. Jedna určuje náležitost v třídě a nula nikoli. Modul *FuzzyConnectDistance* poskytuje algoritmus založený na metodě fuzzy connectedness. Modul se využívá k segmentaci kulovitých objektů a objektů, které nemají jednoznačně viditelné hranice vzhledem k pozadí. Nejprve se na jednom z obrázků umístí do zájmové oblasti počáteční semena. Algoritmus na bázi hodnot šedi vypočítá náležitost voxelů k objektu pro celou sérii obrazových dat.

Výše popsané metody vyžadují minimální interakci uživatele. Nevýhodou těchto automatických přístupů je, že výpočet probíhá u celé série obrazových dat a vyznačení nelze u jednotlivých obrázků měnit. V nástroji lze také provést poloautomatická 2D segmentace. Moduly, které v názvu zahrnují zkratku CSO (Contour Segmentation Object), umožňují vyznačení hranic objektu. Například modul *SoCSOLiveWireEditor* používá LiveWire algoritmus, *CSOIsoGenerator* aplikuje na vstupní data metodu IsoSurface či *SoCSOPolygonEditor* umožňuje uživateli vyznačit hranice objektu manuálně. Kontury objektů nemusí být vyznačovány na každém snímku. Prostor mezi nimi lze dopočítat například modulem *CSOConvertTo3DMask*, jenž využívá rekurzivní metodu Marching Cubes.

#### **5.4. Moduly určení k vizualizaci dat**

Po použití segmentačního algoritmu či kombinaci algoritmů je nutné vytvořit povrchovou trojúhelníkovou síť, která bude daný objekt prezentovat. K tomuto účelu slouží modul *IsoSurface*. Modifikací je modul *WEMIsoSurface*, jenž generuje povrch dle určité prahové hodnoty, na základě které vytváří síť. Dají se v něm nastavit parametry maximální a minimální hodnoty iso povrchu. Hodnoty voxelů nižší než je hodnota minimální nebo vyšší, než je maximální, jsou považovány za pozadí a hodnoty, které do rozmezí spadají za požadovaný objekt. *SoExaminerViewer* slouží k následné vizualizaci vytvořeného modelu.

Moduly určené pouze k prohlížení dat jsou *View2D*, který zobrazuje dvourozměrná obrazová data s možností listování mezi jednotlivými řezy a *View3D*, jenž slouží k vykreslení 3D datové sady.

## 6. Navržené řešení

V této kapitole je navržené řešení, jež zpracovává barevná medicínská obrazová data formátu PNG.

Jak již bylo zmíněno v předchozí kapitole, je výhodné pracovat s daty ve formátu DICOM. Jsou-li na vstupu data jiného formátu (BMP, PNG, JPG) k převodu je navržen konvertor Onis 2.6 Ultimate<sup>2</sup>. Při konverzi dat není v nástroji umožněno specifikovat vzdálenost mezi jednotlivými snímky. Data poté neobsahují tzv. spacing between slices informaci. Tato informace musí být dále specifikována. V případě, že se nespecifikuje (obr. č. 15), vytvořené modely nezachovávají původní umístění v prostoru.



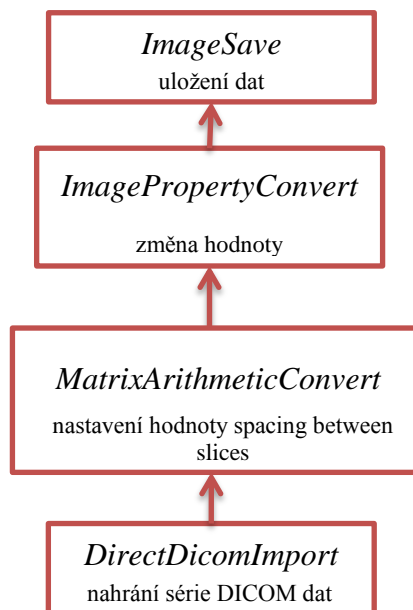
Obrázek 15 – Výsledné modely po konverzi dat na DICOM bez definice vzdálenosti mezi snímky

Byly vyzkoušeny i jiné nástroje, ale většina z nich byla nevyhovujících, protože nevytvářely tzv. tagy, což poté způsobilo, že v nástroji nebylo možné nahrát sérii medicínských obrazových dat, ale pouze jeden obrázek.

Vzdálenost mezi jednotlivými snímky je umožněno specifikovat v nástroji MeVisLab. Algoritmus je znázorněn na obr. č. 16 a program v příloze A. Skrze *DirectDicomImport* se nahraje série DICOM dat. V modulu *MatrixArithmeticConvert* jsou původní hodnoty, jenž je možné upravit maticí B. V *ImagePropertyConvert* se hodnoty pro vstupní data

<sup>2</sup>Webová stránka stažení nástroje: <http://www.onis-viewer.com/ProductInfo.aspx?id=17>

aktualizují. Následně se data modulem *ImageSave* uloží nejlépe do formátu DICOM/TIFF. Pokud jsou data importována jako jednotlivé fotografie, modul *ImageSave* je umožňuje uložit v maximálně dvou souborech (DICOM/TIFF). Po tomto kroku není umožněno do nástroje MeVisLab nahrát pouze část fotografií. Výpočty pak mohou trvat mnohonásobně déle.

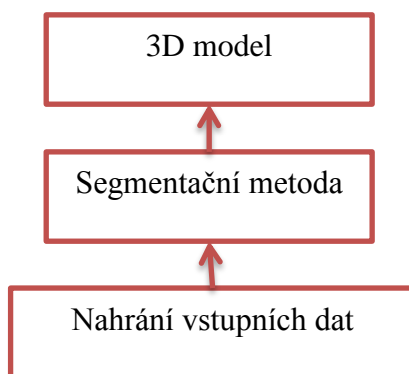


Obrázek 16 – Algoritmus specifikace prostorové informace v nástroji MeVisLab

## 6.1. Obecný postup segmentace objektu

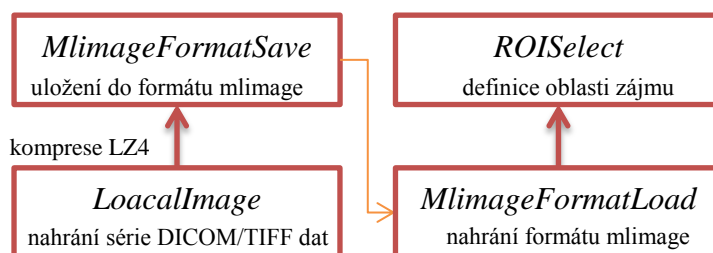
Postup pro vytvoření 3D modelu požadované struktury lze rozdělit do tří fází. Tyto fáze byly naprogramovány a uloženy ve formátu mlab, který je umožněno spustit v nástroji MeVisLab.

V první fázi se nahrají vstupní data. Je důležité poznamenat, že pro snazší práci s nástrojem by na vstupu měly být pouze ty snímky, na kterých se daný objekt nachází. V další fázi se na načtená vstupní data aplikuje některý ze segmentačních algoritmů tak, aby došlo k vyznačení požadovaného objektu. V posledním kroku se vyznačený model převede na povrchovou síť. Obecný algoritmus segmentace je demonstrován na obr. č. 17.



Obrázek 17 – Obecný algoritmus segmentace

Import vstupních dat lze provést více způsoby. Nejvýhodnějším je nahrát DICOM/TIFF data skrze modul *LocalImage* a následně je uložit pomocí modulu *MImageFormatSave*. Modul data zkomprimuje a uloží do formátu *mImage*. Nejvhodnější typ komprese je LZ4, který je bezztrátový a zaměřený na rychlost. Následně se nahrají modulem *MImageFormatLoad*. Definice zájmové oblasti je umožněna modulem *ROISelect*. Algoritmus je na obr. č. 18.

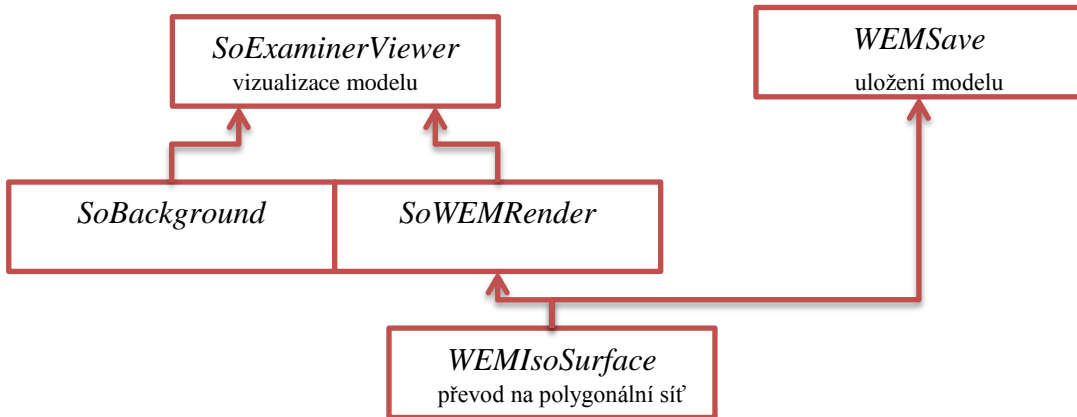


Obrázek 18 – Algoritmus nahrání dat

Moduly, určené k segmentaci, jsou popsány v kapitole 4.3. Pokud je struktura dobře oddělitelná od pozadí, lze na vstupní data aplikovat metodu prahování či algoritmus fuzzy cluster. Je-li nutné segmentovat objekt uvnitř jiného, je výhodné použít algoritmus narůstání oblastí. Má-li objekt nevýrazné hranice, nabízí se možnost využít 2D segmentaci. V mnoha případech je k dosažení kvalitních výsledků nutné zkombinovat více metod najednou. Z důvodů, že má každý modul specifické parametry, vstupní i výstupní data, výsledný algoritmus v nástroji u každého druhu segmentace vypadá jinak.

Poslední fázi se vyznačená struktura převede na trojúhelníkovou síť. Převod zprostředkovává modul *WEMIsoSurface*. Vizualizace je umožněna již v nástroji prohlížečem

*SoExaminerViewer*, který ke své funkci potřebuje pomocné moduly *SoWEMRender* a *SoBackground*. Pro uložení nově vytvořeného 3D modelu se použije *WEMSave*, v němž lze nastavit výstupní formát. Algoritmus poslední fáze je na obr. č. 19.




Obrázek 19 – Algoritmus vizualizace a uložení modelu

### 6.1.1. Segmentace kůže

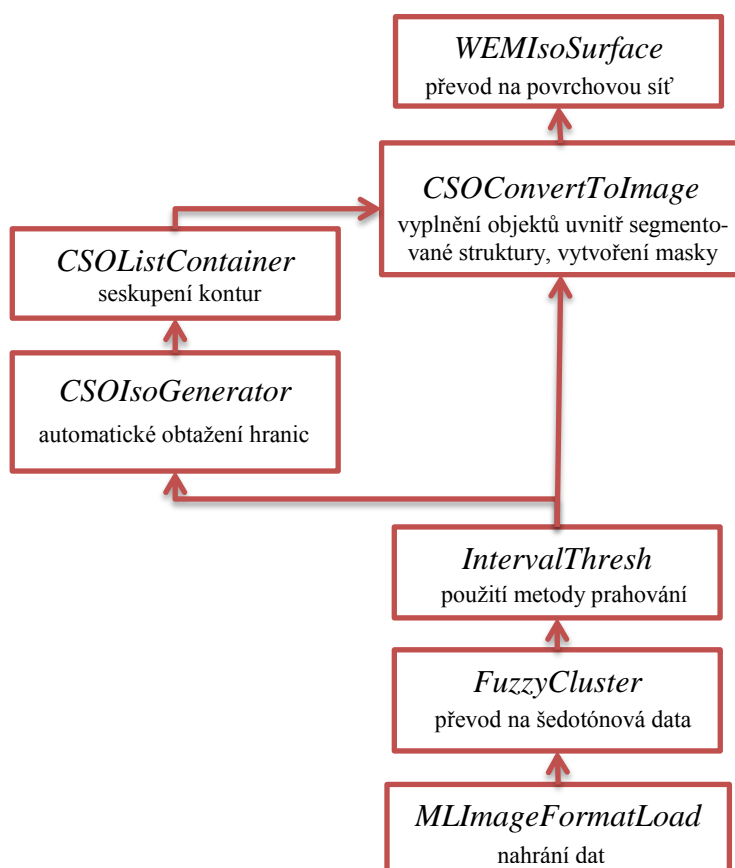
V této podkapitole jsou popsány dva přístupy pro vytvoření 3D modelu kůže, které byly navrženy, realizovány a otestovány. Vycházelo se přitom z faktu, že se odděluje pozadí od samotného kadáveru, a tedy hodnoty jasu objektu jsou různé od hodnot jasu ledu. První přístup je plně automatický a klíčová je metoda prahování, druhý je také automatický a využívá algoritmus IsoSurface.

Metodu prahování v nástroji MeVisLab implementuje modul *IntervalThresh*. Metoda na vstupu předpokládá černobílá vstupní data. Jsou-li k dispozici barevné snímky, lze je převést modulem *FuzzyCluster*. Prahováním nelze v některých případech zajistit, aby byla zvýrazněna pouze kůže, a to z důvodu, že hodnoty jasu voxelů uvnitř kadáveru mohou být podobné či dokonce stejné jako ty na pozadí (obr. č. 20). Tento jev může být způsoben tím, je-li pozadí vzduch nebo led, tak například v průdušnici je také vzduch či led. Vznik nežádoucích struktur také nastane, převedla se barevná data na černobílá. Zatímco u barevných byly některé hranice výrazné u černobílých tomu tak být nemusí, protože pixel již nespecifikují tři komponenty, ale pouze jedna.



Obrázek 20 – Segmentace kůže metodou prahování. Zvýrazněné jsou struktury uvnitř i vně, jež nejsou součástí kůže.

Nechtěně zvýrazněné části uvnitř objektu lze odstranit pomocí kombinace několika modulů. Modul *CSOIsoGenerator* automaticky obtáhne všechny zvýrazněné struktury. Kontury se sdruží a očíslojí v modulu *CSOListContainer*. *CSOConvertToImage* převádí kontury na masky objektů pomocí algoritmu Marching Cubes. V modulu je možné zaškrtnout políčko *fill*, které zajišťuje výplň objektu v případě, je-li definován konturami, z nichž jedna je podmnožinou té druhé. Následně se modulem *WEMisoSurface* vygeneruje trojúhelníková síť. Algoritmus je znázorněn na obr. č. 21.



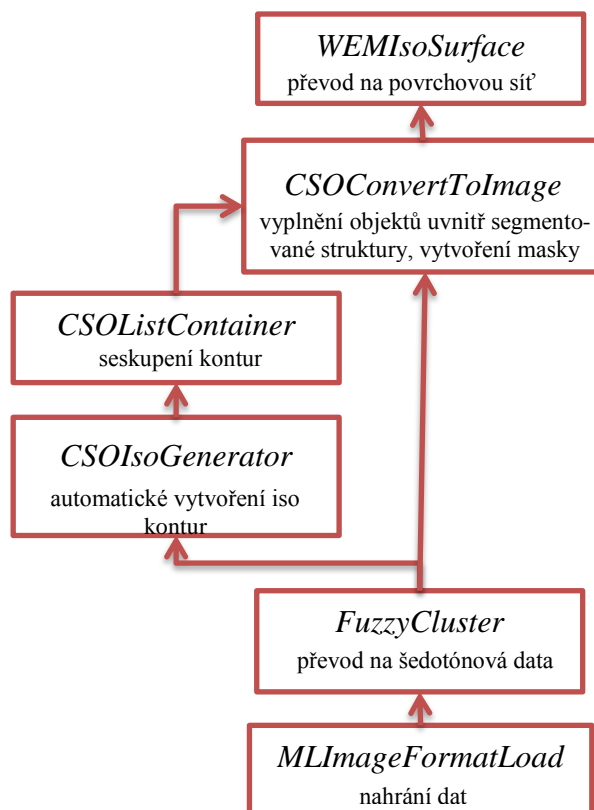
Obrázek 21 – Algoritmus klíčové části metody prahování

V některých případech je možné, že se zvýrazní i nežádoucí struktury v pozadí (obr. č. 20). K odstranění těchto objektů poslouží modul *WEMDemergePatches*. V modulu




se nastaví mód *Area Percentage*, který odstraní objekty s definovaným procentuálním zastoupením. Ve všech případech tvořily objekty méně než dvacet procent výsledného modelu. Program zahrnující metodu prahování zobrazuje příloha B.

U druhého navrženého přístupu je klíčový modul *CSOIsoGenerator*, který automaticky generuje kontury na základě uživatelem specifikované iso hodnoty. Modul skenuje každý vstupní snímek a algoritmem *Marching Cubes* vytváří kontury, jež jsou vždy uzavřené a jejich hodnota je nižší než definovaná iso hodnota. Celý postup je obdobný jako předchozí. Rozdíl spočívá pouze v nevyužití metody prahování. Algoritmus je na obr. č. 22 a program v příloze C.



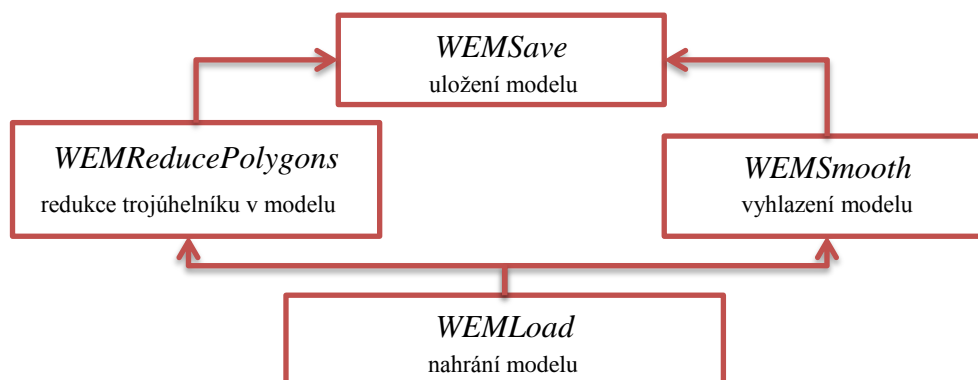
Obrázek 22 – Algoritmus klíčové části metody *IsoSurface*

Obvykle dalším krokem je optimalizace vygenerované polygonové sítě (obr. č. 23). Při segmentaci se objevují typické artefakty, například tzv. schodišťový artefakt, který je odstraněn vyhlazením. Dále se zmenšuje velikost, a to snížením počtu trojúhelníků [5].



Obrázek 23 – Optimalizace polygonové sítě

Popsané optimalizace jsou v nástroji umožněny pomocí modulů *WEMSmooth* a *WEMReducePolygons* (obr. č. 24). V nástroji byl vytvořen program, jenž nahrává polygonální síť skrze modul *WEMLoad*. Uložení upraveného modelu zajišťuje modul *WEMSave*. Program, jenž zahrnuje tato vylepšení, je znázorněn v příloze D. V nástroji je možné v prohlížečích pozorovat změny, které jsou na objekt aktuálně aplikované.




Obrázek 24 – Algoritmus úprav modelu

### 6.1.2. Segmentace kostí, svalů

Při vytváření 3D modelů svalů a kostí je nejprve nutné zvážit, jaký segmentační algoritmus použít. V této podkapitole je popsána poloautomatická 2D segmentace s různými přístupy.

Je-li jasová intenzita kostí podobná jako u ostatních částí v obraze, metoda prahování či fuzzy cluster nevyznačí požadovaný objekt přesně. Algoritmus narůstání oblastí by v případě dat z počítačové tomografie mohl být vhodný. Jsou-li na vstupu barevná

obrazová data, metoda nevyznačí požadovaný objekt přesně (obr. č. 25). Na základě experimentu byla navržena poloautomatická 2D segmentace, jenž spočívá ve vyznačení kontur uživatelem a dotvoření prostoru mezi jednotlivými konturami.



Obrázek 25 – Okno modulu *RegionGrowingMacro*. V levé části obrázku je na barevných vstupních datech vyzkoušena metoda narůstání oblasti s cílem vyznačit pánevní kost.

2D segmentaci lze v nástroji MeVisLab provést několika různými postupy. Vyznačování kontur uživatelem může být manuální či doplněné o metodu IsoSurface nebo LiveWire. Následně se z kontur vytváří maska objektu.

Pro manuální vyznačení je klíčový modul *SoCSOPolygonEditor*, který umožňuje vyznačit hranici objektu pomocí polygonu. Nevýhodou mohou být vrcholy, jež polygon obsahuje. Přístup je vhodný použít, nejsou-li v obraze viditelné hranice. Uživatel musí mít apriorní znalost o tom, co segmentuje.

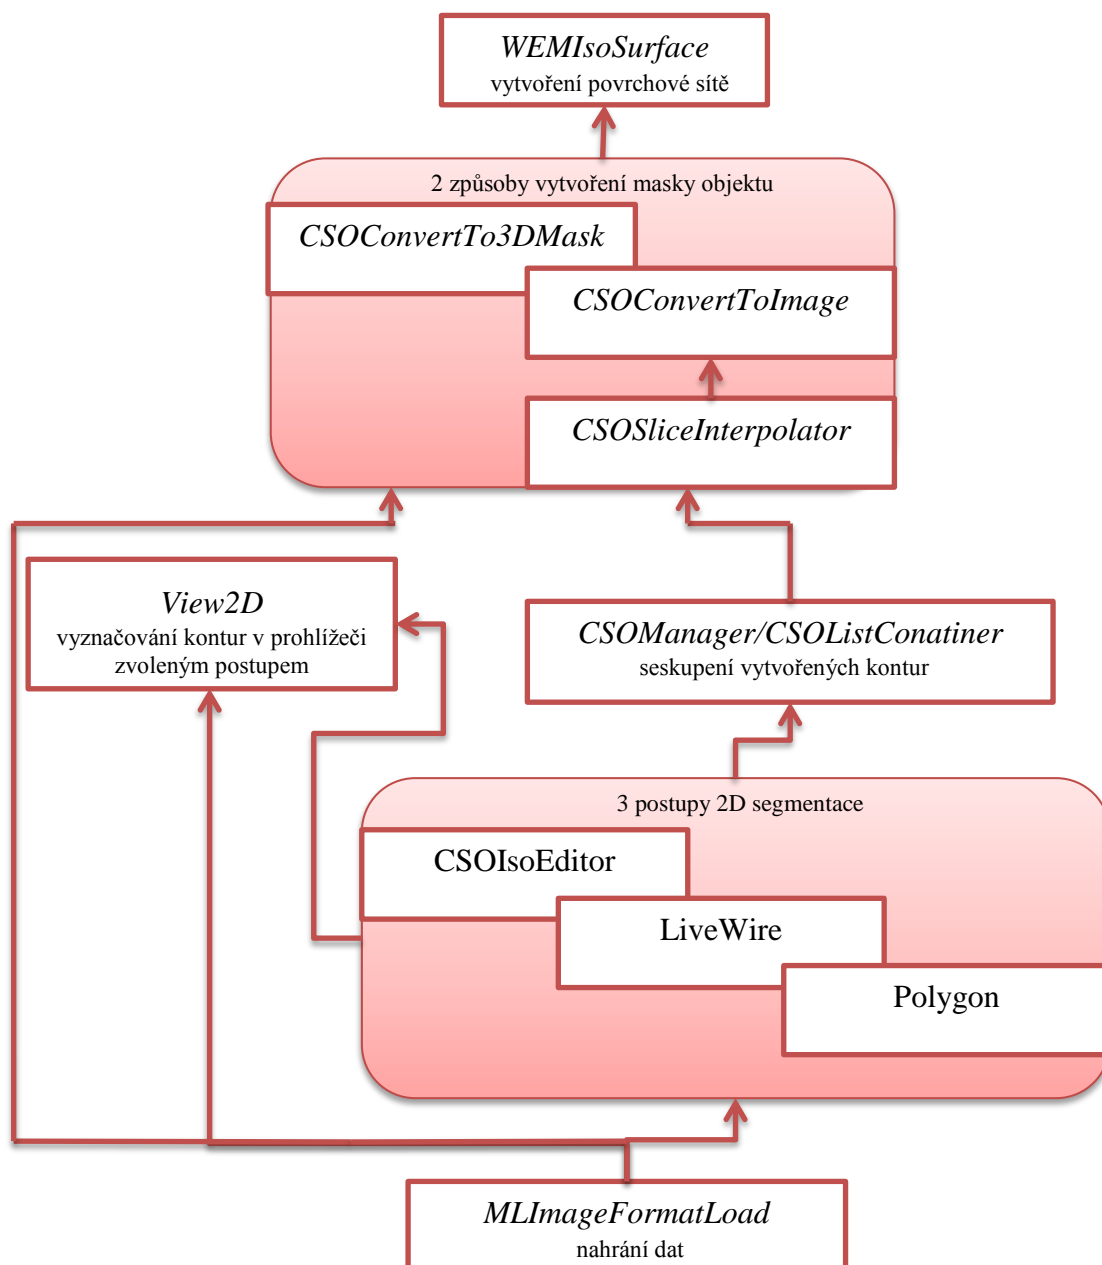
IsoSurface implementuje modul *CSOIsoGenerator*, který interaktivně generuje iso kontury. Pod kurzorem myši je hodnota, která slouží pro výpočet průběhu křivky. Tažením pravým tlačítkem myši se hodnota aktualizuje a kontura rozšiřuje. Přístup je žádoucí, má-li objekt výrazné hranice.

*SoCSOLiveWireEditor* implementuje metodu LiveWire. Vytvářená kontura se automaticky přimyká k hranicím objektů. Přístup lze použít, jsou-li hranice objektu zřetelné. V případech, kde nejsou viditelné, uživatel musí provést pro vytvoření kontury více uzlů.

Vytvořit masku a dopočítat prostor mezi konturami je umožněno dvěma způsoby. První z nich implementuje modul *CSOConvertTo3DMask*. Modul využívá 3D thin plate spline (TPS) implicitní funkci s podmínkou, že vytvořené kontury budou součástí výsledného povrchu, a rekurzivní algoritmus Marching Cubes. Podrobnější popis se nachází v článku Shape Transformation Using Variational Implicit Function [22]. *CSOConvertTo3DMask* je vyhovující při vytváření kulových či elipsoidových objektů bez ostrých hran.

U druhého způsobu se využijí dva moduly. První z nich *CSOSliceInterpolator* vytváří interpolované kontury paralelně s osou znové kontury na základě již vytvořených. Interpolace je provedena stanovením spline surface funkce. Jednotlivé snímky jsou skenovány a v místech, kde nejsou kontury vyznačené uživatelem, jsou doplňovány. Následně se použije modul *CSOConvertToImage*. Kontury se převedou na linii šesti voxelů. Maska je poté vytvářena algoritmem Marching Cubes na základě hodnot, jež tyto voxely obsahují. V manuálu nástroje, konkrétně u nápovědy modulů *CSOConvertToImage* a *CSOSliceInterpolator* jsou algoritmy detailněji vysvětleny. Moduly na vstupu předpokládají černobílá vstupní data.

Možnosti vyznačení kontur a jejich převedení na masku objektu lze kombinovat. Algoritmus, znázorňující propojení modulů za účelem sestrojení 2D segmentace, je na obr. č. 26. V modulu *MImageFormatLoad* se nahrají vstupní data. Vybere se přístup pro vyznačení kontur a v modulu *View2D* se vyznačí. Kontury se seskupí a následně se dvěma možnými způsoby vytvoří maska objektu. V modulu *WEMIsoSurface* se maska převede na polygonální síť.



Obrázek 26 – Algoritmus 2D segmentace v nástroji MeVisLab s třemi možnými postupy


Vygenerovaný model je opět možné různými způsoby optimalizovat. Možnosti jsou popsány v předchozí podkapitole 5.1.1.

## 7. Dosažené výsledky

V této kapitole jsou vyobrazené 3D modely, které byly vytvořené v nástroji MeVisLab. Jako vstupní data byly použity fotografie z projektu Visible Human Project, které zachycují nařezané zamražené ženské tělo v rozmezí třetiny milimetru. Obrázky jsou ve formátu PNG. Rozměry jsou 2048 x 1216 pixelů a bitová hloubka je 24, jenž značí, že k popisu barvy je 16 777 216 bitů. Počet fotografií přesahuje 5 000 a velikost dat 15 GB.

Během vytváření těchto modelů bylo nutné vyřešit několik záležitostí. Z důvodů, že bylo poskytnuto více než 5 000 fotografií, nabývaly obrázky velikosti v řádu desítek GB. Práce s takovýmto objemem dat byla velmi časově náročná.

Za účelem zmenšení velikosti byly obrázky oříznuty v nástroji FastStone Viewer 5.5<sup>3</sup>. Nástroj umožňuje nahrát celou složku a dle zadaných parametrů obrázky jednotně oříznout a zároveň jim změnit rozlišení. Byly oříznuty pouze části v pozadí (obr. č. 27), jež nezobrazovaly samotný kadáver. Rozlišení se snížilo z původních 2048 x 1216 pixelů na 1619 x 947 pixelů. Celkový objem dat byl zmenšen z 15 GB na 1,3 GB, tedy téměř o 92%. V nástroji MeVisLab je také možnost modulem *ROISelect* obrázky jednotně oříznout, ale u takto velkých vstupních dat je tento postup několikanásobně delší než předchozí. Dále byla data zredukována a zmenšena. Použila se každá třetí fotografie a velikost se zmenšila o jednu třetinu.



Obrázek 27 – Snímky z projektu Visible Human Project. Vlevo snímek před oříznutím, vpravo po oříznutí.

Pro konverzi dat z formátu PNG do formátu DICOM byl použit nástroj Onis 2.6 Ultimate. Jelikož nástroj neumožňuje specifikovat vzdálenost mezi jednotlivými řezy, mu-

<sup>3</sup> Webová stránka stažení nástroje: <http://www.faststone.org/download.htm>


sely se výpočty provádět nad celou sérií fotografií. Program používá složité výpočty, a proto využívá velké množství paměti počítače. Při testování programu na různých strojích byla plně využita i kapacita 64 GB RAM, nahrála-li se celá série dat. Z tohoto důvodu byl univerzitou umožněn přístup na virtuální stroj s velikostí paměti RAM 128 GB. V tomto případě již ke komplikacím s pamětí nedocházelo.

### 7.1. Model kůže

Pro vytvoření modelu kůže byly použity dva postupy popsané v kapitole 5.1.2. V prvním případě byla použita metoda prahování a ve druhém IsoSurface. Oba dva přístupy jsou plně automatické. Výsledky, jež vznikly z dat z projektu Visible Human Project odpovídají realitě a jsou téměř totožné. Rozdíly jsou zanedbatelné.

U obou metod je klíčové nastavení parametrů. V případě prahování je to prahový interval, který byl nastaven v rozmezí 0-95. Interval byl určen na základě experimentů. U metody IsoSurface je rozhodující iso hodnota, která byla nastavena na hodnotu 95.

Dále byl vyzkoušen poloautomatický postup, jenž využívá 2D segmentace a metody IsoSurface. Celkem bylo vytvořeno 146 kontur. Výsledky postupů jsou na obr. č. 28.



Obrázek 28 – Optimalizovaný model kůže vytvořený v nástroji MeVisLab. Vlevo automatickou metodou prahování, vpravo poloautomatickou 2D segmentací a metodou IsoSurface.

Porovná-li se výsledné modely, z obr. č. 28 je zřejmé, že model vygenerovaný metodou prahování je přesnější. Rovněž je i kvalitativně lepší. Polygonová síť obsahuje 1 452 480 trojúhelníků a 724 989 vrcholů, zatím co model vytvořený metodou Is-


oSurface má 2 810 466 trojúhelníků a 1 405 120 vrcholů, což je téměř dvakrát tolik. Časová náročnost interakce uživatele je mnohonásobně nižší, použije-li se automatický postup využívající metodu prahování, taktéž i časová náročnost výpočtu.

Pro vytvoření modelu kůže je žádoucí použít automatický přístup. V případě interaktivního se nedojde k přesným výsledkům a časová náročnost je mnohonásobně větší.

## 7.2. Modely kostí

Jako nejvhodnější pro barevná vstupní data byl vyhodnocen poloautomatický postup, jenž využívá 2D segmentace a manuálního vyznačení kontur uživatelem. Prostor mezi konturami byl dotvořen modulem *CSOConvertTo3DMask*, který využívá implicitní funkce a algoritmu Marching Cubes. Program je přiložen v příloze E.

Byly vyzkoušeny i jiné přístupy pro vyznačení kontur, ale výsledky byly mimo očekávání z důvodů, že v některých případech byly nejasné hranice. Převážně mezi kostí a hyalinní chrupavkou či mezi kostmi samotnými. Kost má tři typy kostní dřevě (červenou, žlutou a bílou). Na snímcích, kde se nacházel kloub, bylo velmi složité rozeznat, zda se jedná o typ kostní dřevě nebo o chrupavku. Na obr. č. 29 je fotografie, na které není na první pohled evidentní, kde jsou hranice kyčelního kloubu a pánevní kosti.




Obrázek 29 – Snímek znázorňující nejasné hranice kyčelního kloubu a pánevní kosti.

Automatický přístup byl v tomto případě nepoužitelným taktéž interaktivní doplněný o metodu IsoSurface. V případě algoritmu LiveWire bylo nutné vytvořit podstatně více uzlů. Náročnost výpočtu se poté mnohonásobně zvýší.

Modely byly vytvářené na počítači s 8 GB paměti RAM. Vytvoření modelu kosti tibia trvalo přibližně 30 minut, přičemž samotné vytvoření kontur zabralo 10 minut a výpočet



20 minut. Z důvodů snížení časové náročnosti výpočtů byly vytvářeny kontury pouze v místech, kde se hranice kosti výrazně měnily a bylo použito co nejméně vrcholů. Celkem bylo vytvořeno v případě kosti tibia 15 kontur. Při testování segmentačního postupu na virtuálním stroji s pamětí 128 GB RAM bylo vytvořeno u té samé kosti 35 kontur s vysokým počtem vrcholů. Samotné vytváření kontur trvalo 15 minut a výpočet pouhé 3 minuty. Rozdílný výsledek je na obr. č. 30.



*Obrázek 30 – Optimalizované modely kosti tibia. Vlevo vytvořený 15 konturami, vpravo 35.*

Pro vytvoření modelu tímto postupem musí mít uživatel apriorní znalost segmentovaného objektu. Pro vytvoření modelu je nutné vyznačit kontury s hranicemi objektu. V tabulce č. 4 je uvedené jak 3D model vybrané struktury odpovídá realitě. Hodnocení bylo provedeno lékařem na modelech vytvořených na virtuálním stroji.

Název objektu	Hodnocení 1-5	Počet kontur	Popis hodnocení
<b>Os femoris (stehenní kost)</b>	4	33	Krček kosti je širší, než je obvyklé. Na tělu kosti jsou menší povrchové nerovnosti a některé linie nejsou viditelné.
<b>Tibia (holenní kost)</b>	4	35	Některé hrany kosti jsou nefyziologicky zvlněné. Abnormální výběžek na horním kondylu na pravé straně. Jinak kost celkově odpovídá realitě.
<b>Os Coaxe (pánevní kost)</b>	3	32	Deformovanější tvar, hlavně acetabulum, foramen obturatum, ramus ossis ischii a os pubis. Některé kloubní spoje jsou špatně znatelné.
Hodnocení na stupnici 1-5: 5 - odpovídá na 100-80% realitě, 4 - odpovídá na 80-60% realitě, 3 - odpovídá na 60-40% realitě, 2 - odpovídá na 40-20% realitě, 1 - odpovídá na 20-0% realitě			

Tabulka 4 – Zhodnocení modelů

Z tabulky je patrné, že modely zcela neodpovídají realitě, ale velmi se jí přibližují. Některým vzniklým nedostatkům nelze předejít vzhledem k použité metodě. Například nerovnostem, z toho důvodu, že kontura je vytvářena jako polygon. Tyto artefakty by mohla eliminovat metoda LiveWire, jenž se přimyká k hraničním objektů (příloha F). Z důvodů, že v datech nejsou dostatečně viditelné hranice, musí uživatel touto metodou vytvořit podstatně více uzlů. Naopak jiným předejít lze, a to přesnějším vyznačením objektu odborníkem.

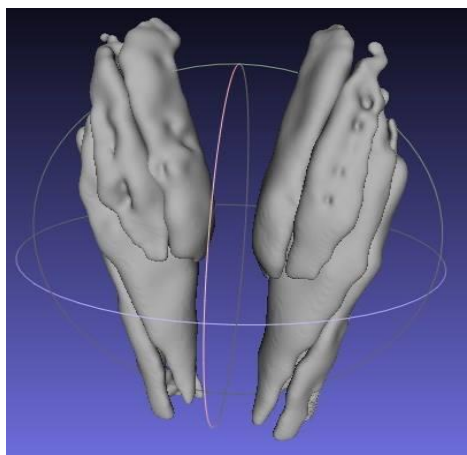
U složitější struktury je segmentace náročnější a uživatel musí vytvořit více kontur. Výsledek je poté závislý na preciznosti. Nevýhodou je při vytvoření většího počtu kontur větší časová náročnost výpočtu v programu.

### 7.3. Modely svalů

Pro vytvoření modelů svalů byla také použita 2D segmentace s manuálním vyznačením hranic. Vzhledem k nejasným hraničním mezi jednotlivými svaly nebylo možné použít automatický přístup. Pro vyznačení kontur byly vyzkoušeny i metody LiveWire a IsoSurface, ale pro stejný důvod byla práce ztížena a hranice se velmi těžko vyznačovaly. Na některých snímcích bylo možné hranice poznat pouze sledováním svalových vláken.

Maska objektu byla vytvořena modulem *CSOConvertTo3DMask*. Tento způsob byl zvolen, protože je žádoucí, nemá-li objekt ostré či rovné hrany.

Celkem bylo vytvořeno 30 modelů svalů, některé z nich jsou na obr. č. 31. Za účelem dosažení větší kvality výstupních modelů je nutné vytvořit více kontur a více uzlů, avšak není žádoucí vytvářet kontury na každém snímku. Uživatel musí mít pro vytvoření modelů svalů apriorní znalost, kde se sval i jeho hranice nachází.




*Obrázek 31 – Optimalizované modely svalů oblasti mezi kotníkem a kolenem vytvořené interaktivní metodou*

## 8. Zhodnocení práce s nástroje MeVisLab

Práce v nástroji MeVisLab je uživatelsky velmi náročná. Nutnými předpoklady pro vytvoření programů v nástroji, je mít povědomí o segmentačních algoritmech a celkově znalosti v oblasti zpracování obrazu. Dále se musí uživatel seznámit s dostupnými moduly, jejich funkcemi a parametry, aby byl schopen moduly mezi sebou propojovat. Uživatelská dokumentace zahrnuje pouze základy, ale není v ní možné nalézt, jak se jednotlivé postupy implementují.

Nástroj primárně předpokládá na vstupu černobílá data. Vzhledem k dostupným datům, nebylo možné použít některé segmentační algoritmy. Pokud se použila barevná data, nejeden modul s nimi neuměl pracovat (obr. č. 32). V případě, že se data převedla na černobílá, staly se některé hranice nejasnými.



Obrázek 32 – Model kůže vytvořený z barevných dat

Dále byla práce v nástroji zkomplikovaná velkým množstvím a formátem vstupních dat. Muselo být provedeno předzpracování, v němž byl převeden formát a zmenšen objem. I přes snížení velikosti vstupních dat, byly výpočty v nástroji velmi časově náročné a zabíraly velké množství paměti počítače.

Kladně je hodnocena široká nabídka modulů a možnost kombinace jednotlivých metod a postupů, ale jak již bylo zmíněno, orientace v modulech je náročná. Dále je přívětivě klasifikován přístup autorů programu, s nimiž byly některé postupy konzultovány. V případě nejasností byli velmi ochotni daný problém vysvětlit, popřípadě navrhnout možné řešení. Kontakt byl umožněn skrze fórum nástroje<sup>4</sup>.

---

<sup>4</sup> Oficiální fórum nástroje MeVisLab: <http://forum.mevis.fraunhofer.de/>

## 9. Závěr

Na základě vytyčených cílů a zásad bakalářské práce byly vyzkoušeny a popsány nástroje určené k segmentaci medicínských obrazových dat, konkrétně MeVisLab, Turtle-Seg, 3D-DOCTOR a ITK-SNAP. Programy používají různé metody a algoritmy, které vytvářejí 3D model požadovaného objektu.

Po analýze jednotlivých nástrojů byl shledán jako nejvíce vyhovující k vytvoření 3D modelu kůže, svalů a kostí software MeVisLab. Důvody, které k tomuto rozhodnutí vedly, jsou: bezplatné používání neregistrované verze, multiplatformnost, možnost výběru a libovolné kombinace segmentačních metod (prahování, LiveWire algoritmus, narůstání oblastí, fuzzy cluster, aktivní kontury) a další funkčnosti nástroje, například použití různých druhů filtrů, transformací a jiných technik zpracování obrazu.

Stěžejní částí práce je návrh několika automatických a poloautomatických postupů pro segmentaci vybraných objektů v nástroji MeVisLab. Automatické postupy jsou založené na prahování nebo metodě IsoSurface. Poloautomatické postupy na 2D segmentaci, přičemž se liší dle způsobu vyznačení kontury. Všechny postupy byly v MeVisLab naprogramovány (bylo využito tzv. „dataflow“ programování). Vytvořené programy je umožněno dále používat či vylepšovat. U každého je napsaný komentář s jednotlivými kroky i s vhodným nastavením parametrů.

Jako vstupní data pro testování byly použity RGB fotografie z projektu Visible Human Project ve formátu PNG. Bylo provedeno jejich ruční předzpracování. Byly použity nástroje Fast Stone Image Viewer ke zmenšení objemu obrázků a Onis ke konverzi dat z formátu PNG do DICOM série. Zpracovávání DICOM série probíhalo v MeVisLab prostřednictvím vytvořených programů. Během zpracování byly vytvořeny modely svalů, kostí a kůže. Celkem bylo vytvořeno 47 modelů. Modely vytvořené nástrojem MeVisLab byly vizualizovány v nástroji Meshlab. Některé byly ohodnoceny lékařem na základě porovnání s realitou.

Experimenty ukázaly, že automatické postupy využívající metodu prahování a IsoSurface jsou vhodné pro segmentaci kůže. Výsledný model kůže je hodnocen velmi pozitivně. V případě svalů a kostí byl jako nejvhodnější postup vyhodnocen poloautomatický, jenž využívá manuálního vyznačení kontur pomocí polygonu. Realističnost modelů vytvořených tímto postupem je poté závislá na preciznosti, množství vytvořených kontur a apriorních znalostech uživatele.

Závěrem je možné konstatovat, že metody a postupy implementované v nástroji MeVisLab, primárně nepracují s RGB daty, ale s černobílými. Převod na šedotónová data vede ke ztrátě informace, jež se projeví v nedokonalosti segmentace. Řešením by mohlo být naprogramování nových modulů s variantou pro barevná data či využití ITK subsystému nástroje a jeho metod.

## Seznam pojmů a zkratek

- DICOM (Digital Imaging and Communications in Medicine) – standart pro zobrazování, distribuci, skladování a tisk medicínských dat pořízených snímacími metodami jako jsou CT, MRI či ultrazvuk.
- ITK (Insight Segmentation and Registration Toolkit) – multiplatformní systém, který poskytuje rozsáhlou sadu softwarových nástrojů pro analýzu obrazu.
- VTK (Visualization Toolkit) – softwarový systém pro 3D počítačovou grafiku, zpracování obrazu a vizualizaci.
  
- voxel – základní jednotka v třídímenzionálním prostoru



## Seznam obrázků

Obrázek 1 - Zpracování obrazu .....	2
Obrázek 2 - Fotografie z projektu Visible Human Project .....	2
Obrázek 3 - 2D segmentace .....	6
Obrázek 4 - 3D povrchový model kosti os femoris, vpravo se zvýrazněnou sítí trojúhelníků, kterou je model tvořen.....	7
Obrázek 5 - 3D model rectus femoris dexter vytvořený paralelními řezy.....	7
Obrázek 6 - Určování hrany [7] .....	9
Obrázek 7 - Identifikace objektů [7].....	10
Obrázek 8 - Metoda aktivních kontur [2] .....	12
Obrázek 9 - Metoda prahování .....	15
Obrázek 10 – Algoritmus v nástroji MeVisLab.....	19
Obrázek 11 - MeVisLab .....	20
Obrázek 12 – 3-D DOCTOR .....	21
Obrázek 13 – TurtleSeg .....	23
Obrázek 14 – ITK-SNAP.....	24
Obrázek 15 – Výsledné modely po konverzi dat na DICOM bez definice vzdálenosti mezi snímky.....	30
Obrázek 16 – Algoritmus specifikace prostorové informace v nástroji MeVisLab .....	31
Obrázek 17 – Obecný algoritmus segmentace.....	32
Obrázek 18 – Algoritmus nahrání dat.....	32
Obrázek 19 – Algoritmus vizualizace a uložení modelu .....	33
Obrázek 20 – Segmentace kůže metodou prahování. Zvýrazněné jsou struktury uvnitř i vně, jež nejsou součástí kůže. ....	34
Obrázek 21 – Algoritmus klíčové části metody prahování.....	34
Obrázek 22 – Algoritmus klíčové části metody IsoSurface .....	35
Obrázek 23 – Optimalizace polygonové sítě .....	36
Obrázek 24 – Algoritmus úprav modelu.....	36
Obrázek 25 – Okno modulu RegionGrowingMacro. V levé části obrázku je na barevných vstupních datech vyzkoušena metoda narůstání oblastí s cílem vyznačit pánevní kost. ....	37
Obrázek 26 – Algoritmus 2D segmentace v nástroji MeVisLab s třemi možnými postupy.....	39

Obrázek 27 – Snímky z projektu Visible Human Project. Vlevo snímek před oříznutím, vpravo po oříznutí.....	40
Obrázek 28 – Optimalizovaný model kůže vytvořený v nástroji MeVisLab. Vlevo automatickou metodou prahování, vpravo poloautomatickou 2D segmentací a metodou IsoSurface. ....	41
Obrázek 29 – Snímek znázorňující nejasné hranice kyčelního kloubu a pánevní kostí.	42
Obrázek 30 – Optimalizované modely kosti tibia. Vlevo vytvořený 15 konturami, vpravo 35. ....	43
Obrázek 31 – Optimalizované modely svalů oblasti mezi kotníkem a kolenem vytvořené interaktivní metodou .....	45
Obrázek 32 – Model kůže vytvořený z barevných dat .....	46

## Seznam tabulek

Tabulka 1 – Souhrn vlastností testovaných programů pro segmentaci medicínských dat .....	25
Tabulka 2 – Typy modulů MeVisLab.....	26
Tabulka 3 – Typy konektorů MeVisLab.....	27
Tabulka 4 – Zhodnocení modelů .....	44

## Literatura

- [1] ŠPANĚL, Michal – BERAN, V. *Obrazové segmentační techniky - Přehled existujících metod* [online]. Brno: Vysoké učení technické v Brně. Fakulta informačních technologií, c2005, poslední revize 19.1.2006. [cit.2016-4-14]. Dostupné z <[http://www.fit.vutbr.cz/~spanel/segmentace/#\\_Toc125769325](http://www.fit.vutbr.cz/~spanel/segmentace/#_Toc125769325)>.
- [2] HOLOTA, Radek – FIŘT, J. *Digitalizace a zpracování obrazu*. Plzeň: Západočeská univerzita v Plzni. Nové technologie - výzkumné centrum, 2002.
- [3] BUKAČ, František. *Referát na Umělou inteligenci - POČÍTAČOVÉ VIDĚNÍ* [online]. České Budějovice: Jihočeská univerzita v Českých Budějovicích. Fakulta pedagogická. Katedra informatiky, c2010. [cit. 2016-4-14]. Dostupné z <<http://www.galahad.wz.cz/pcvideni/index.htm>>.
- [4] HRAZDIRA, Ivo – MORNSTEIN, V. – ŠKORPÍKOVÁ, J. *Základy biofyziky a zdravotnické techniky*. Brno: Neptun, c2006. s 204-225. ISBN 80-86850-01-3.
- [5] REINER, Robert – HARDERS, M. *Virtual Reality in Medicine*. Londýn: Springer-Verlag, 2012. s. 234–245. ISBN: 978-1-4471-4010-8.
- [6] ŽÁRA, Jiří – BENEŠ, B. – SOCHOR, J. *Moderní počítačová grafika*. 2., přeprac. a rozš. vyd. Brno: Computer Press, c2004. s. 609. ISBN 80-251-0454-0.
- [7] PARKER, J. R. *Algorithms for image processing and computer vision*. 2. rozš. vyd. New York: John Wiley & Sons, c2011. s. 21–58. ISBN 978-0-470-64385-3.
- [8] KASS, Michael – WITKIN, A. – TERZEPOULOS, D. Snakes: Active Contour Models. *International Journal of Computer Vision*. Boston: Kluwer Academic Publisher. c1987, roč. 117, č. 323, s. 321–331. ISSN 0920-5691.
- [9] XU, Juan – CHEW, P. – CHUTATAPE, O. Automated Optic Disk Boundary Detection by Modified Active Contour Model. *IEEE transactions on biomedical engineering*, 2007, roč. 54, č. 3, s. 473 - 482.
- [10] ZIMMER, Christophe – OLIVO-MARIN, J.C. Coupled Parametric Active Contours. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, roč. 27, č. 11, s. 1838 - 1842.
- [11] GOLDENBERG, Roman – KIMMEL, R. – RUDZSKY, M. – RIVLIN, E. Fast Geodesic Active Contours. *IEEE Transactions on Image Processing*, 2001, roč. 10, č. 10, s. 1467 - 1475.
- [12] BARRETT, William A. – MORTENSEN, E.N. Interactive Live-Wire Boundary Extraction. *Oxford University Press*. USA: Brigham Young University. Department of Computer Science, 1996/7, roč. 1, č. 4, s. 331 - 341.

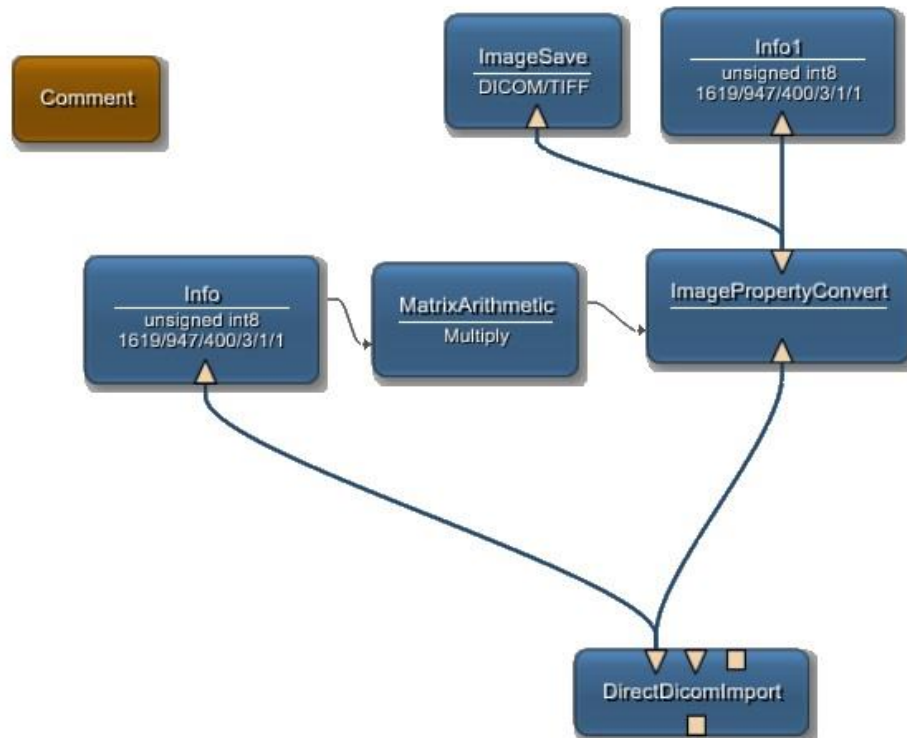
- [13] ADAMS, Rolf – BISCHOP, L. Seeded Region Growing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1994, roč. 16, č. 6, s. 641 - 647.
- [14] PHAM, Dzung L. – XU, Ch. – PRINCE, J.L. Current Methods in Medical Image Segmentation. *Annual Review of Biomedical Engineering*, srpen 2000, roč. 2, s. 315-337.
- [15] ROERDINK, J. B. T. M. – MEIJSTER, A. The Watershed Transform: Definitions, Algorithms and Parallelization Strategies. *Fundamenta Informaticae*, 2001, roč. 41, s. 187–228.
- [16] Neuronové sítě a jejich využití. *SystemOnLine* [seriál online]. Česká republika: CCB spo. s.r.o, březen 2014, [cit. 2015-12-28]. ISSN 1802-615X.  
Dostupné z: <[http://www.statsoft.cz/file1/PDF/newsletter/2013\\_02\\_05\\_StatSoft\\_Neuronove\\_site\\_linky.pdf](http://www.statsoft.cz/file1/PDF/newsletter/2013_02_05_StatSoft_Neuronove_site_linky.pdf)>.
- [17] RITTER, Felix. – T. BOSKAMP, T. – HOMEYER, A. – LAUE, H. – SCHWIER, M. – LINK, F. – PEITGEN, H. Medical Image Analysis. *IEEE Pulse*, 2011, roč. 2, č. 6, s. 60 - 70. ISSN 2154-2287.
- [18] *MeVisLab* [online]. MeVis Medical Solutions AG, c2016 [cit. 2015-11-09].  
Dostupné z: <<http://www.mevislab.de>>.
- [19] *3D - DOCTOR* [online]. Able Software spol., c1994-2016 [cit. 2015-11-09].  
Dostupné z: <<http://www.ablesw.com/3d-doctor>>.
- [20] *TurtleSeg* [online]. University of British Columbia: Oxipita Inc, c2010-2016 [cit. 2015-12-28]. Dostupné z: <<http://www.turtleseg.org>>.
- [21] GERIG, Guido – GEE, J.C. – HO, S. – SMITH, R.G. – HAZLETT, H.C. – PIVEN, J. – YUSHKEVICH, P.A. *ITK-SNAP* [online]. 2006 [cit. 2016-02-23].  
Dostupné z: <<http://www.itksnap.org>>.
- [22] TURK, Greg – O'Brian, J. F. Shape Transformation Using Variational Implicit Function. *Georgia Institute of Technology*, srpen 1999, s. 335 – 342.

## Seznam příloh

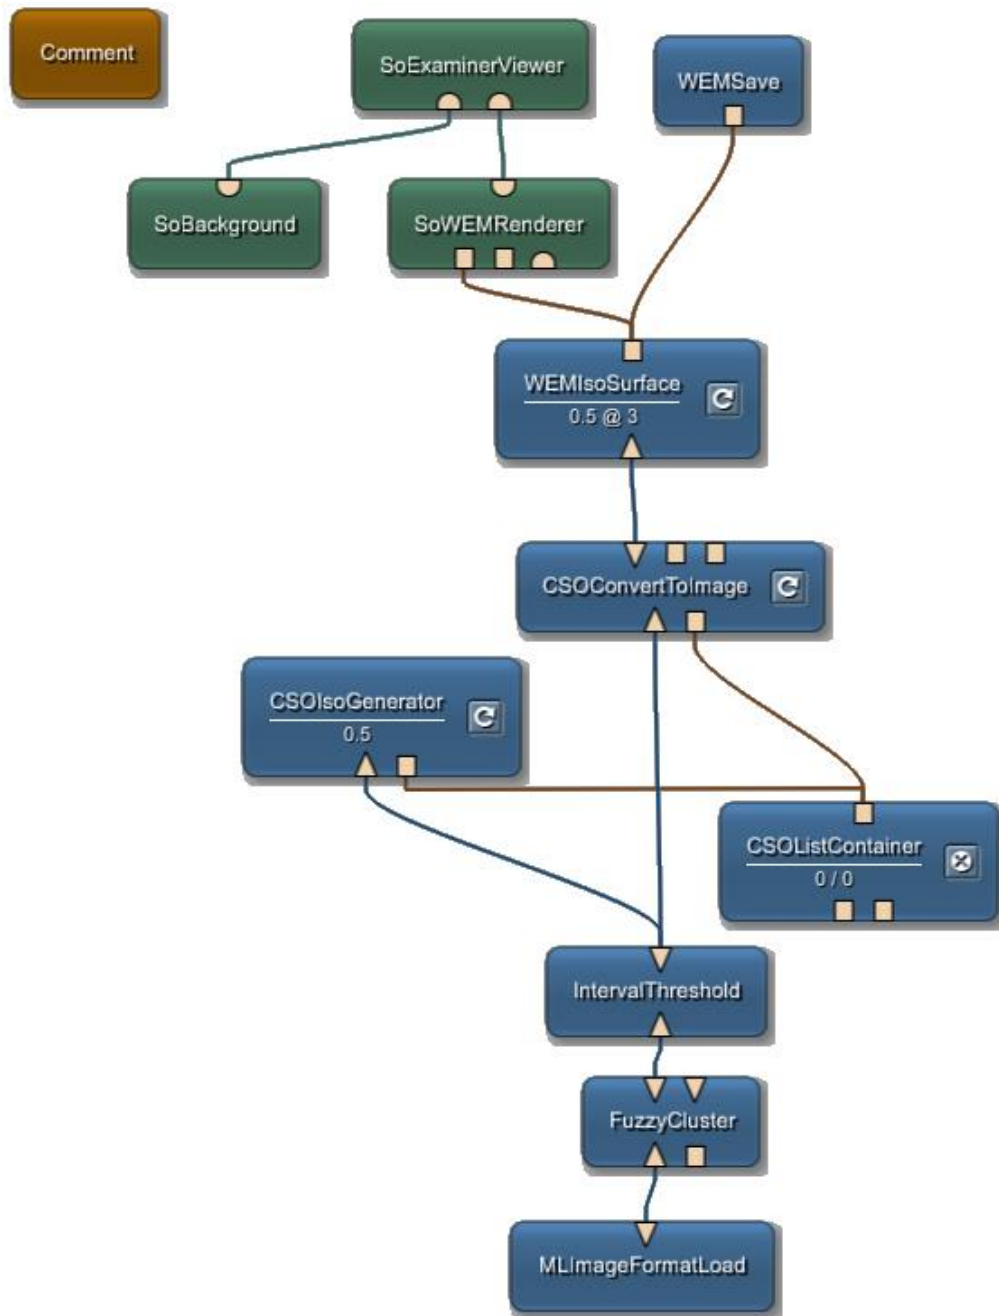
<b>Příloha A</b> – Program k definování informace spacing between slices .....	57
<b>Příloha B</b> – Program k vytvoření 3D modelu metodou prahování .....	58
<b>Příloha C</b> – Program k vytvoření 3D modelu metodou IsoSurface.....	58
<b>Příloha D</b> – Síť pro úpravu 3D modelu (redukce polygonů, vyhlazení, odstranění objektů v pozadí) .....	58
<b>Příloha E</b> – Síť pro vytvoření 3D modelu polygony .....	58
<b>Příloha F</b> – Síť pro vytvoření 3D modelu LiveWire algoritmem .....	58

# Přílohy

## Příloha A – Program k definování informace spacing between slices

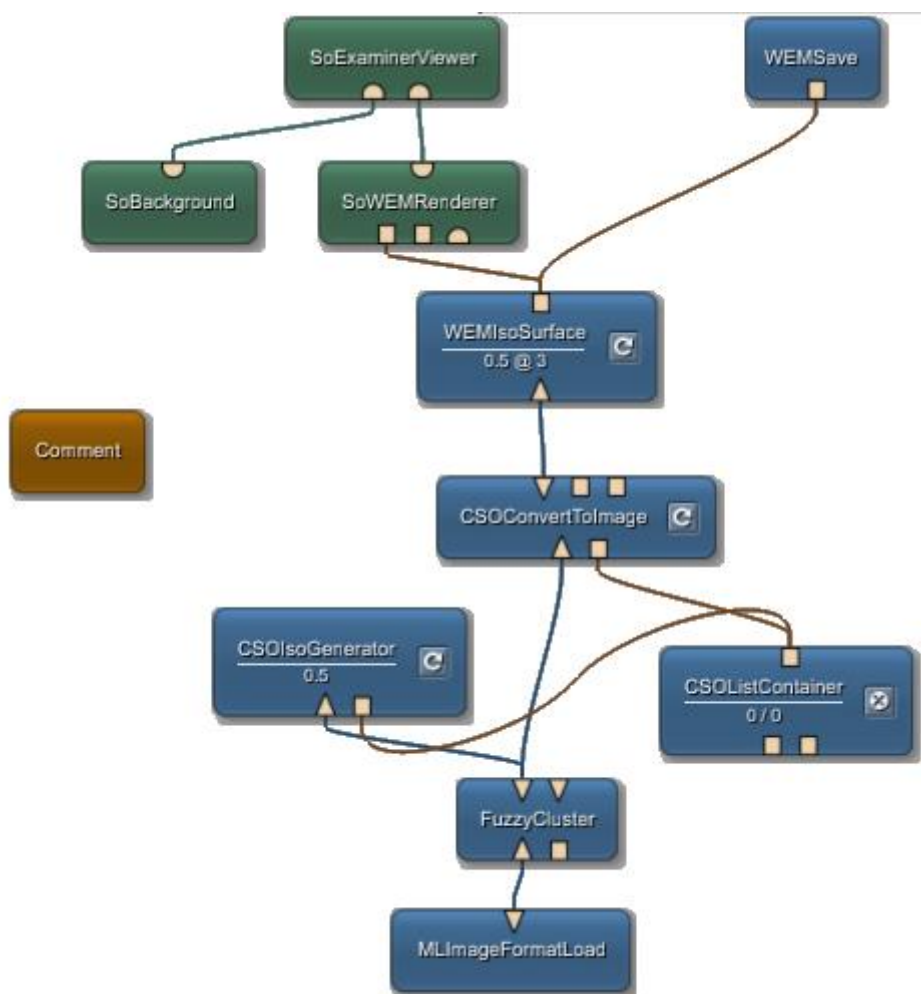


**Příloha B** – Program k vytvoření 3D modelu metodou prahování

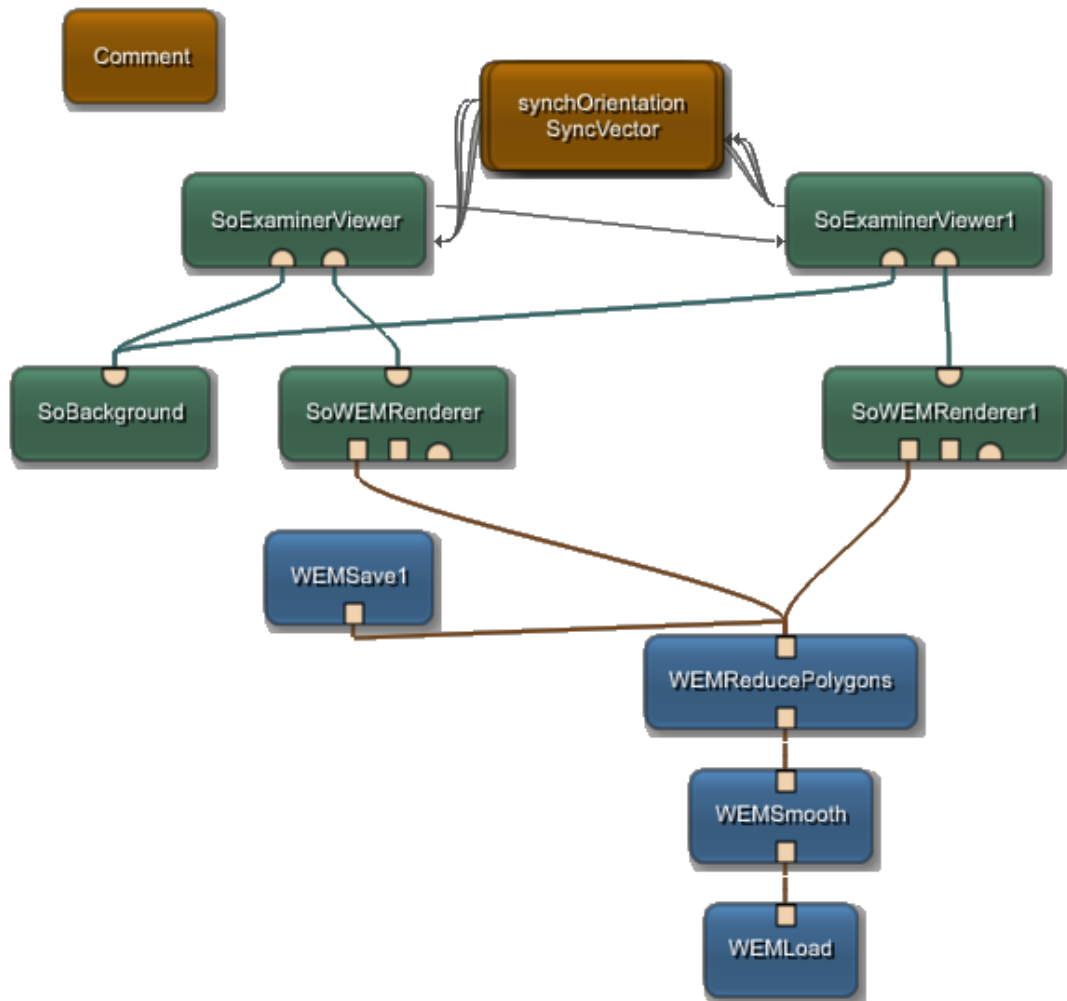




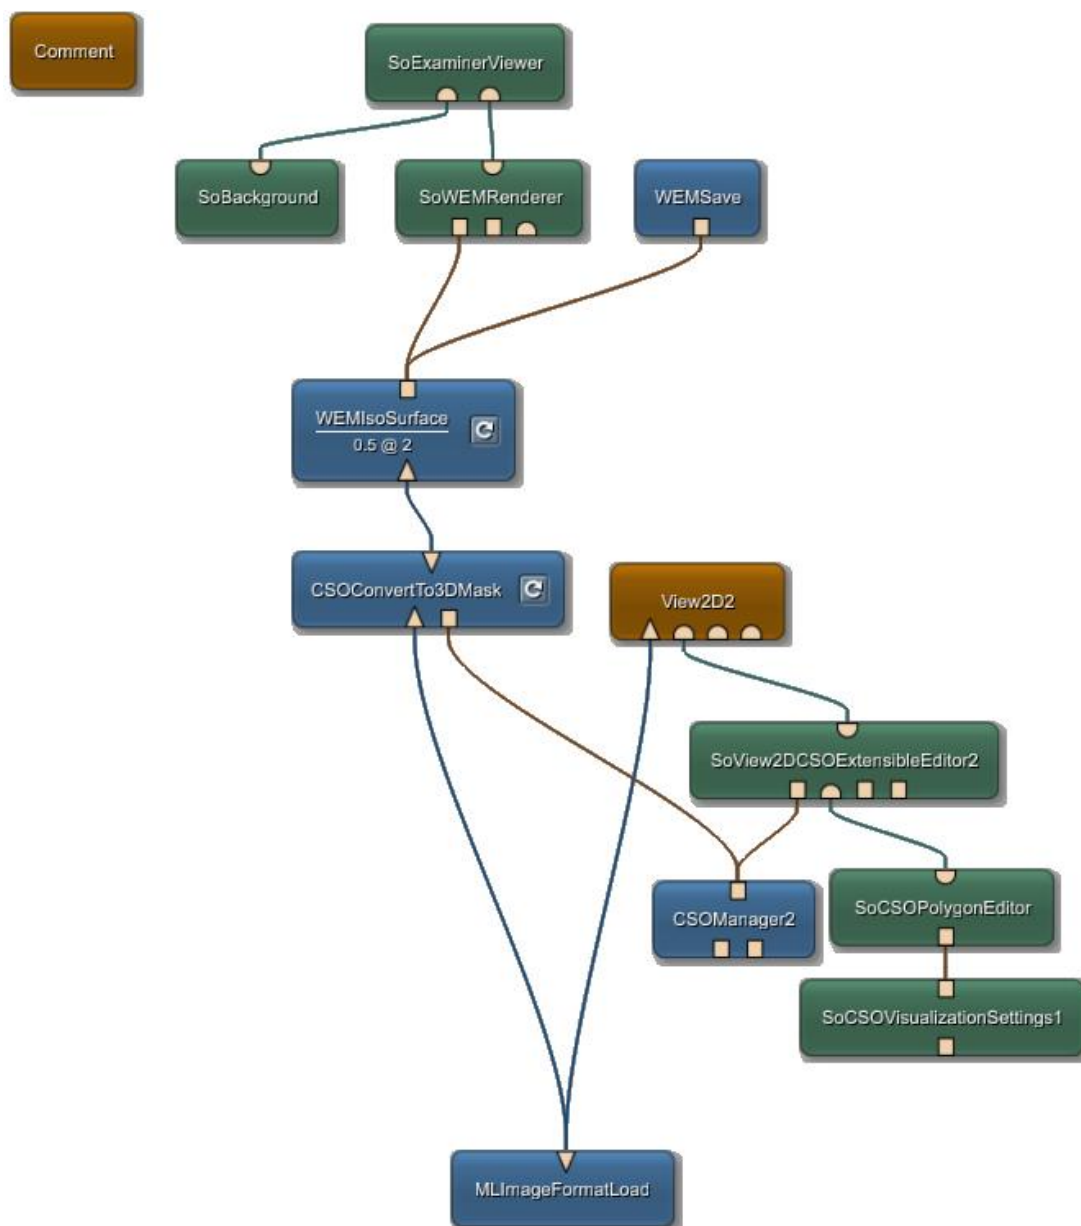
### Příloha C – Program k vytvoření 3D modelu metodou IsoSurface



**Příloha D** – Síť pro úpravu 3D modelu (redukce polygonů, vyhlazení, odstranění objektů v pozadí)



## Příloha E – Síť pro vytvoření 3D modelu polygony



**Příloha F** – Síť pro vytvoření 3D modelu LiveWire algoritmem

