

Západočeská univerzita v Plzni
Fakulta aplikovaných věd
Katedra kybernetiky

DIPLOMOVÁ PRÁCE

PLZEŇ, 2015

Martin Červený

ZÁPADOČESKÁ UNIVERZITA V PLZNI

Fakulta aplikovaných věd

Akademický rok: 2014/2015

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Martin ČERVENÝ**
Osobní číslo: **A13N0156P**
Studijní program: **N3918 Aplikované vědy a informatika**
Studijní obor: **Kybernetika a řídicí technika**
Název tématu: **Segmentace jater z obrazů z trojrozměrných zobrazovacích metod**
Zadávací katedra: **Katedra kybernetiky**

Z á s a d y p r o v y p r a c o v á n í :

1. Seznamte se s využitím výpočetní tomografie a magnetické rezonance pro medicínské aplikace.
2. Seznamte se s prostředky pro zpracování trojrozměrných obrazových dat v jazyce Python.
3. Navrhněte metody segmentace jater z CT a MRI.
4. Proveďte porovnání navržené metody se segmentací metodou Graph-Cut.
5. Zhodnoťte získané výsledky.

Rozsah grafických prací: **dle potřeby**

Rozsah pracovní zprávy: **40-50 stránek A4**

Forma zpracování diplomové práce: **tištěná**

Seznam odborné literatury:

NEKULA, Josef; HEŘMAN, Miroslav, et al. Radiologie. 3. vyd. Olomouc: Univerzita Palackého v Olomouci, 2005. Dotisk 2008. ISBN 978-80-244-1011-7. S. 205. (cs)

Sonka M., Hlavac V. , Boyle R.: Image Processing, Analysis, and Machine Vision, 3rd edition, Thomson Learning, Toronto, April 2007, 821 p, ISBN 049508252X (2nd edition Brooks/Cole, Pacific Grove, CA, 1999, 1st edition Chapman & Hall, London 1993, 4th edition scheduled for 2013).

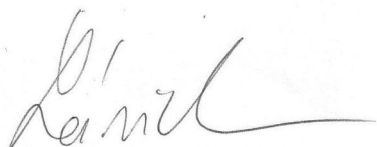
Vedoucí diplomové práce:

Ing. Miroslav Jiřík

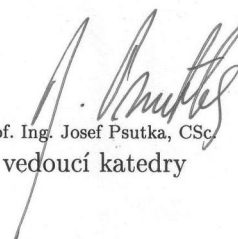
Nové technologie pro informační společnost

Datum zadání diplomové práce: **1. října 2014**

Termín odevzdání diplomové práce: **15. května 2015**



Doc. RNDr. Miroslav Lávička, Ph.D.
děkan



Prof. Ing. Josef Psutka, CSc.
vedoucí katedry

V Plzni dne 1. října 2014

PROHLÁŠENÍ

Předkládám tímto k posouzení a obhajobě diplomovou/bakalářskou práci zpracovanou na závěr studia na Fakultě aplikovaných věd Západočeské univerzity v Plzni.

Prohlašuji, že jsem bakalářskou/diplomovou práci vypracoval(a) samostatně a výhradně s použitím odborné literatury a pramenů, jejichž úplný seznam je její součástí.

V Plzni dne

.....

Anotace

Cílem této diplomové práce je vyvinout automatickou metodu pro segmentaci jater z CT snímků v rámci dostupných prostředků. Po uvedení problému a nastínění CT a MRI je metoda podrobně popsána. Je udán odkaz na její veřejně přístupnou implementaci v jazyce Python. Výsledky jsou srovnány s komerčními metodami za použití převzaté vyhodnocovací metodiky. Je proveden pokus o srovnání s interaktivní metodou Graph-Cut, avšak kvůli nedostatku dat je učiněn pouze nepodložený a hrubý odhad.

Klíčová slova

segmentace jater, automatická, počítačová tomografie, zpracování obrazu

Annotation

The aim of this thesis is to develop an automatic method for segmentation of liver from CT images within limits of available resources. After introduction of the problem and outline of CT and MRI the method is described in detail. A link to its implementation in Python, available to public, is given. Results are compared with commercial methods using an adopted method for evaluation. An attempt is made of comparison of the method with an interactive method Graph-Cut, but because of lack of data only an unfounded and rough estimate is made.

Key words

liver segmentation, automatic, computed tomography, image processing

Obsah

1 Úvod	1
2 Formulace problému	2
2.1 Počítačová tomografie (X-ray computed tomography, CT)	2
2.1.1 Rentgenové záření v CT	2
2.1.2 CT přístroj	2
2.1.3 Definice úlohy	4
2.2 Magnetická rezonance (magnetic resonance imaging, MRI)	4
2.2.1 Fyzikální princip MRI	4
2.2.2 MRI snímek	6
2.3 Metodika vyhodnocení	6
2.3.1 Skóre	7
2.3.2 Chyba objemového přesahu (VOE, volumetric overlap error)	7
2.3.3 Relativní odchylna objemů (RVD, relative volume difference)	7
2.3.4 Průměrná vzdálenost povrchů (ASD, average symmetric surface distance)	8
2.3.5 Kvadratický průměr vzdáleností povrchů (RMSD, root mean square symmetric surface distance)	9
2.3.6 Maximální vzdálenost povrchů (MSD, maximum symmetric surface distance)	9
3 Navržený způsob řešení	10
3.1 Představení metody, blokové schéma	10
3.2 Inteligentní metoda prahování	11
3.2.1 Popis principu histogramu a prahování	11
3.2.2 Diskuze prahování pro danou úlohu	12
3.2.3 Popis inteligentní metody prahování	14
3.2.4 Ukázka výsledků, diskuze změn parametrů	18
3.3 Filtrace prahovaného obrazu	22
3.3.1 Popis principu diskrétní konvoluce	22
3.3.2 Diskuze filtrace pro danou úlohu	25
3.3.3 Popis metody filtrace prahovaného obrazu	26
3.3.4 Ukázka výsledků filtrace	28
3.4 K-means odstínová kvantizace	29
3.4.1 Popis Lloydova algoritmu	29
3.4.2 Použití Lloydova algoritmu v metodě	31
3.4.3 Diskuze k-means vektorové kvantizace	32
3.5 Vybrání žádoucích oblastí	32
3.5.1 Popis metodiky vybrání žádoucích oblastí	32
3.5.2 Diskuze metodiky vybrání žádoucích oblastí	35
3.6 Post proces	36
3.6.1 Popis binárních operací dilatace, eroze a uzavření	36
3.6.2 Popis metody postprocesu (závěrečného zpracování)	38
4 Vyhodnocení výsledků	41
4.1 Jazyk Python a jeho prostředky pro zpracování trojrozměrných dat, implementace	41
4.1.1 Python, jeho výhody a nevýhody	41
4.1.2 Prostředky jazyka Python pro zpracování trojrozměrných dat	41
4.1.3 Projekt <i>LISA</i> a implementace	42
4.2 Výsledky experimentů	43
4.2.1 První experiment	43
4.2.2 Analýza pozorovaných chyb	46
4.2.3 Druhý experiment – časová náročnost	49
4.2.4 Diskuze vlivu změny rozlišení	50
4.2.5 Srovnání s metodou Graph-Cut	50
4.2.6 Možnosti použití metody pro MRI	52
5 Závěr	53
Literatura	54
Seznam obrázků	56

1 Úvod

Analýza trojrozměrných snímků získaných pomocí medicínských přístrojů (počítačová tomografie, magnetická rezonance) je denní náplní práce odborníků z oblasti medicíny. Ve většině případů kdy je potřeba více než pouze prohlédnout snímek, například vypočítat objem orgánu, ji odborníci provádí ručně za pomoci pravítek. Tato činnost je poměrně zdlouhavá a zabírá čas odborníků, tedy je ideální kandidát pro zastoupení člověka strojem. Cílem této práce je vyvinout a popsat metodu, která automaticky (bez jakéhokoli zásahu operátora) vybere oblast z trojrozměrného snímku tak, jako by to dělal odborník, a to pouze pro jeden orgán, konkrétně játra, a zahrnout ji do společného projektu ZČU a Fakultní nemocnice Plzeň, konkrétně její přidání do aplikace *LISA*.

Odborník dokáže bez problémů určit, kde ve snímku se nachází játra. I laik znalý anatomie je relativně dobře schopen určit okraje jater, případně určit okraje jiného orgánu. Úloha však není ze strojového hlediska vůbec triviální, naopak je skvělým příkladem toho, že člověk vnímá obrazovou informaci jinak než stroj. V případě počítačové tomografie je problém i s nejjednodušším prahováním, protože játra mají na snímku stejnou intenzitu jako velká část zbytku těla. Dále intenzita uvnitř jater není úplně homogenní a tvoří zvláštní strukturu, hlavně portální žíla do jater vstupující má velmi odlišné hodnoty než zbytek jater. Játra i u zdravých jedinců jsou různě velká, mají různý tvar a doléhají na různé orgány, přičemž tyto změny mezi jedinci jsou nejvýraznější snad ze všech orgánů. To je za předpokladu že jedinci jsou zdraví, do nemocnice nastupují hlavně nemocní, a pokud jsou předmětem zájmu játra, nejspíš bude poškozená jejich struktura, bude se v nich nacházet nějaké cizí těleso a podobně.

Další problém je samotné měření. I když vyšetření provádí přístroj, může dojít k chybě obsluhy (například špatná koncentrace kontrastní látky), což je zanedbáno. Snímky je také možné pořizovat s různým rozlišením, přičemž nízké rozlišení vede ke ztrátě informace o struktuře jater (efekt částečného objemu), a vysoké rozlišení k nárůstu šumu. Rozlišení je v dostupné množině různé, tedy toto není zanedbáno, i když ne dostatečně.

Množina byla získána na stránkách soutěže *Sliver07.org*, které jsou věnovány soutěži, která shrnuje dosavadní pokrok v této oblasti. Velká část metod je poloautomatických, tedy vyžadují nějaký vstup od uživatele (velmi časté je například vložení seedů – určení několika vnitřních bodů jater). Všechny metody v soutěži byly vyvíjeny řadou odborníků, obvykle za podpory grantů a různých programů. Většina nejlepších metod není popsána, a některé úspěšné jsou dokonce odevzdány anonymně. Tato práce dostupnými prostředky nemůže těmto metodám konkurovat, jejím cílem je se jim pouze přiblížit a poskytnout informace veřejně, jelikož aplikace je veřejně dostupná.

2 Formulace problému

2.1 Počítačová tomografie (X-ray computed tomography, CT)

Počítačová tomografie (CT) je druh neinvazivního vyšetření pacienta. Jelikož se tato práce zabývá segmentací ze snímků CT, je vhodné alespoň nastínit, jak jsou tyto snímky získávány, a také zdůraznit a shrnout důsledky, které pro práci z měření plynou. Pro definici úlohy pracující s CT snímkem je logicky nezbytná definice ct snímku. Toto krátké nastínění předpokládá znalost základů částicové fyziky. Pro podrobnější popis problematiky viz [2].

2.1.1 Rentgenové záření v CT


Rentgenové záření je elektromagnetické záření s vlnovou délkou 10^{-8} až 10^{-12} metru. Jeho objevitelem je Wilhelm Conrad Röntgen a od doby jeho objevu v roce 1895 je nedocenitelným nástrojem v medicíně. Vlastností rentgenového záření je, že prochází materiálem, a částečně je jím pohlcováno, přičemž množství pohlceného záření závisí na složení materiálu.

Elektromagnetické záření je proud částic - fotonů. Při pohlcování fotonu záření atomem materiálu může dojít k jednomu ze dvou fyzikálních jevů. Prvním je excitace. Při excitaci atomu je energie fotonu předána elektronu, který postoupí na vyšší energetickou hladinu atomu. Po čase se navrátí zpět, přičemž vyzáří foton. Druhým jevem je ionizace. V tomto případě je elektron vytržen z atomu a jeho místo zaplní elektron z vyšší energetické hladiny. Stejně jako u excitace při jeho sestupu dojde k vyzáření fotonu záření.

Rentgenové záření používané v CT přístrojích je vytvářeno v takzvaných rentgenkách, ve kterých je anoda a katoda, mezi kterými je určité napětí. Katoda vysílá elektrony směrem k anodě a při jejich dopadu dochází k excitaci a ionizaci, jako je popsáno výše, jen s tím rozdílem že částicí způsobující jev není foton, ale elektron. Tak vzniká takzvané charakteristické rentgenové záření protože energie vyzářených fotonů závisí jen na složení anody a nabývá určitých hodnot. Druhou složkou záření vycházející z rentgenky je brzdné záření, které vzniká při zakřivení dráhy elektronů ve hmotě, a jejich zpomalení, přičemž ztráta jejich energie se projeví jako vyzářený foton. Energie takto vyzářených fotonů závisí na původní rychlosti elektronu a vytváří spojité spektrum. Celkové záření rentgenky je pak kombinace brzdného a charakteristického záření.

2.1.2 CT přístroj

CT přístroj se skládá z jedné či více rentgenek a sady detektorů intenzity rentgenového záření. Počty obou součástí mohou být různé, CT přístroje se podle toho dělí na generace I-IV.



Obrázek 1: generace CT

Další dělení CT přístrojů je na konvenční a spirální. Konvenční provede otočku v jedné rovině, poté se posune a následně provede další otočku v posunuté rovině. Spirální CT provádí souvislý rotační i posuvný pohyb najednou.

V obou případech jsou získána data v radonově prostoru (kde na jedné ose jsou úhly pod kterými jsou daná data získána), snímek v tomto prostoru se nazývá sinogram. Pro vypočítání snímku existuje více možností, například použití filtrované zpětné projekce, zpětná (dvourozměrná) fourierova transformace nebo iterativní metody. Ve všech případech se jedná o řešení úlohy zpětné radonovy projekce z radonova prostoru do trojrozměrného prostoru CT snímku. Tato práce se touto úlohou nezabývá, ani nemůže zvolený algoritmus ovlivnit. Pracuje až se získanými snímky. CT snímek lze definovat jako soubor voxelů:

$$CT = V_1 \dots V_N, N = X \cdot Y \cdot Z$$


$$V_n = [x_n, y_n, z_n, hu_n], x \in 1 \dots X, y \in 1 \dots Y, z \in 1 \dots Z$$

Snímek má tři rozměry: X , Y a Z , dále místo absorpčních koeficientů a (viz níže) se používá pro každý voxel hodnota v Hounsfieldových jednotkách, kdy -1000 HU je hodnota vzduchu a 0 HU je hodnota vody. Tato vlastnost je důležitá z důvodu kalibrace, kdy tzv. fantom, neboli objekt se známými absorpčními koeficienty (vzduch, voda) se používá pro kalibraci přístroje.

$$HU = 1000 \cdot \frac{a - a_{\text{vody}}}{a_{\text{vody}} - a_{\text{vzduchu}}}$$

CT snímek je tedy trojrozměrné pole voxelů. Voxel je trojrozměrný element CT snímku a představuje průměr intenzity záření uvnitř jeho hranic. Má rozměry x_d , y_d a z_d , které jsou shodné pro všechny voxely, určitou pozici ve snímku a Hounsfieldovo číslo. Rozměry x_d a y_d jsou obvykle stejné, a u daného přístroje se nemění. Často je však

snímkováno s různým rozlišením v ose Z. Při vyšším rozlišení narůstá šum, při nižším rozlišení se ztrácí informace (dochází k efektu částečného objemu – průměrování z více různých částí). Právě rozlišení je třeba při návrhu metod segmentace vzít v potaz. Dalším důsledkem je, že určité části těla se nachází v určitých rozmezech na Hounsfieldově škále.



Obrázek 2: CT snímek a voxel

2.1.3 Definice úlohy

Úlohou této práce je nalézt takový soubor voxelů v CT snímku, který by vybral odborník při úloze označit játra. Metodik popisu rozdílu dvou těles v trojrozměrném prostoru existuje celá řada. Pro danou problematiku byla vytvořena metodika, která je popsána dále, viz 2.3 Metodika zhodnocení.

2.2 Magnetická rezonance (magnetic resonance imaging, MRI)

Magnetická rezonance (MRI) je (podobně jako CT) neinvazivní vyšetření pacienta. Má některé společné vlastnosti s CT (struktura výsledku), avšak fyzikální princip, a hlavně hodnoty čísel ve snímku jsou odlišné. Podobně jako u CT následuje velmi zjednodušený popis fyzikálního principu a shrnutí důsledků pro segmenaci MRI snímků. Podrobnější informace je možné vyčíst z [2].

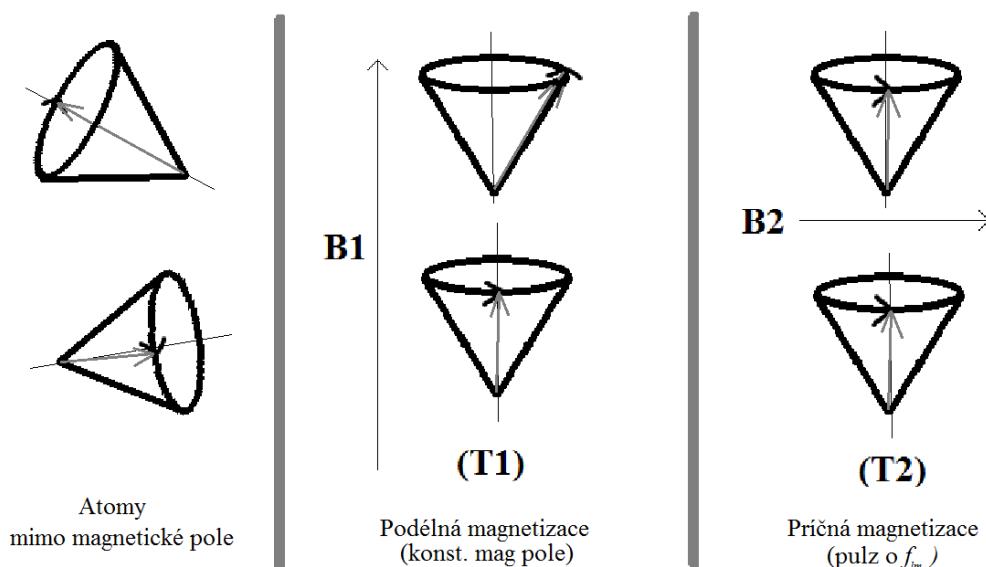
2.2.1 Fyzikální princip MRI

Každá elementární částice v jaderné fyzice má vlastní rotaci, tzv. spin. Jádro atomu má také svůj spin, daný součtem spinů všech nukleonů. V případě že počet nukleonů je sudý, dojde k rovnováze (vytvoření párů) a spin je nulový. V případě lichého počtu nukleonů je spin nenulový, kladný náboj rotuje a vzniká tak magnetický moment.

Hodnota magnetického momentu se odvíjí od Planckovy konstanty a struktury jádra – gyromagnetického poměru γ . Gyromagnetický poměr je pak určující pro frekvenci rotace při precesním (viz obrázek) pohybu jádra při vložení do magnetického pole o intenzitě B_0 – Larmorovu frekvenci f_{lm} :

$$f_{lm} = \gamma \cdot B_0 / 2\pi$$


Z toho vyplývá že různé atomy mají různé frekvence. V MRI se používá měření vodíku ^1H (jeden proton, jeden elektron) s $\gamma = 42,58 \text{ Mhz/T}$. Na následujícím obrázku jsou tři stavy dvojice atomů vodíku ^1H (magnetické momenty vyznačeny šedě):



Obrázek 3: Princip MRI

První je stav, kdy jsou atomy mimo magnetické pole. Směry rotace atomů jsou náhodné a magnetické momenty se nijak neprojevují. Magnetizace tkáně je nulová. Při vložení do konstantního magnetického pole o intenzitě B_1 rotují kolem jedné osy s odpovídající frekvencí, ale s různou fází. Vzniká vektor podélné magnetizace, daný počtem atomů jejichž orientace vzhledem k ose převažuje. Příčná magnetizace tkáně (kolmo na B_1) je nyní nulová – fáze jsou stále náhodné. K tomu aby byla zajištěna stejná fáze je třeba magnetického pulzu B_2 o stejné frekvenci s jakou rotují jádra (Larmorova frekvence f_{lm}). Dojde tak ke změně velikosti a směru magnetizace tkáně. Příčná magnetizace je nyní nenulová, tedy větší. Podélná magnetizace je menší v důsledku uspořádání vektorů v jedné rovině (v případě opačného směru osy rotace - na obrázku není vyobrazeno – je rozdíl nejmenší možný).

Po skončení impulzu se magnetizace vrací do stavu konstantního pole B_1 . V MRI se měří časy T1 a T2. T1 je návrat podélné magnetizace na 63% původní hodnoty, T2 je pokles vektoru příčné magnetizace na 37% jeho hodnoty.



Obrázek 4: časy T1 a T2

Jelikož se jedná o změny magnetického pole, jsou měřeny cívkami, a výsledný signál je uložen do tzv. k-prostoru, ze kterého je získán 3D snímek pomocí Fourierovy transformace. Jelikož se jedná o vrchol dnešní medicínské techniky, metody se neustále vyvíjí a mění. Moderní přístroje jsou schopné měřit další veličinu, protonovou hustotu (proton density, PD) pomocí posloupnosti pulzů. Posloupnosti pulzů jsou také používány pro měření T1 a T2, které se pro vyhodnocování snímků jater převážně používají.

2.2.2 MRI snímek

Stejně jako u CT je MRI snímek složen z voxelů (viz 2.1.2, obrázek 3). Hlavním rozdílem však je, že snímky pořízené různými přístroji, nebo dokonce stejným přístrojem v různých časech, pro libovolnou tkáň (či dokonce fantom) mají rozdílné absolutní intenzity, rozdílné kontrasty (rozsah hodnot snímku) a rozdílnou kvalitu snímku, závislou na nastavení parametrů přístroje. Mezi další nevýhody patří cena vyšetření, která je vyšší než u CT, a některé kontraindikace (přítomnost kovových částí v těle pacienta) které u CT neplatí. Výhodou MRI oproti CT je však obecně vyšší rozlišení a kontrast tkání, hlavně měkkých, tedy včetně jater. Definice úlohy je tedy stejná jako pro CT (viz 2.1.3), až na Hounsfieldovu škálu a CT čísla, se kterými v MRI snímku počítat nelze. Během vývoje metody pro segmentaci CT snímků bylo zjištěno, že metoda pro MRI by byla stejně či více náročná a její vyvinutí by tak přesahovalo rámec této práce. Obhajoba její absence a diskuze možných přístupů k řešení viz 4.2.5

2.3 Metodika vyhodnocení

Jedná se o metodiku převzatou z práce [1]. S úspěchem byla použita v soutěži Sliver 07.org. Následuje její krátké shrnutí. Metriky jsou vypočítávány mezi dvěma objekty v trojrozměrném poli voxelů s rozměry x , y a z .

2.3.1 Skóre

Součástí výsledku této metodiky je skóre nabývající od nuly do jedné, které shrnuje všechny ostatní měřené hodnoty do jednoho čísla. Hodnota byla zvolena tak, aby v případě ručního výběru člověkem (vyškoleným, avšak ne expertem) při srovnání s referenčním výsledkem dosáhla 75% a v případě dokonalé shody 100%. Tedy dosažení výsledku 75% lze považovat funkci programu za odpovídající ručnímu výběru. Dále pokud je odchylka čtyřikrát větší než u ručního výběru tak je skóre považováno za 0 (selhání metody). Toho se docílí za použití ruční odchylky E_i (známá pro všechny metriky) a odchylky stroje e_i . Tak se vypočítá hodnota pro každou metriku i :

$$S_i = \max\left(1 - \frac{e_i}{E_i}, 0\right) \forall i$$

Skóre je počítáno z pěti hodnot které jsou popsány dále. Skóre S se vypočítá z komponent S_i jako průměr:

$$S = \frac{1}{5} \sum_i S_i = \frac{1}{5} (S_{VOE} + S_{RVD} + S_{ASD} + S_{RMSD} + S_{MSD})$$

2.3.2 Chyba objemového přesahu (VOE, volumetric overlap error)

Podíl vzájemného přesahu objemu mezi tělesy A (reference) a B (segmentace) v procentech, kdy jako celek je považován společný objem obou těles. Hodnota je převrácena, aby v případě dokonalé shody VOE nabývalo 100% a v případě že obě tělesa mají nulový průnik 0%. Objem představuje počet voxelů.

$$VOE = 100 \left(1 - \frac{A \cap B}{A \cup B}\right)$$

2.3.3 Relativní odchylka objemů (RVD, relative volume difference)

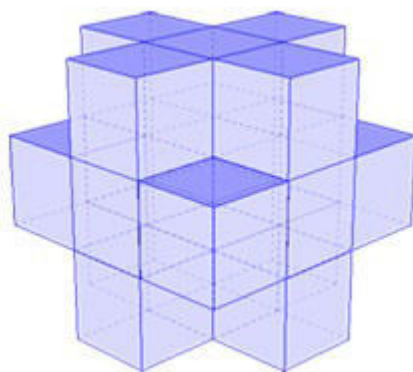
Hodnota rozdílu mezi objemy dvou těles A (reference) a B (segmentace). Hodnota je dělena objemem B a převáděna na procenta, její přínos spočívá v tom, že bez absolutní

hodnoty a převrácení (absence 1-) ukazuje zda-li strojová segmentace určuje menší objem než ruční či naopak. Takto je zahrnuta do tabulky výsledků. Pro výpočet skóre se pak používá s absolutní hodnotou a převrácením.

$$RVD = 100 \left(1 - \frac{|A-B|}{B} \right)$$

2.3.4 Průměrná vzdálenost povrchů (ASD, average symmetric surface distance)

Jako povrchové jsou definovány takové voxely objektu, které mají alespoň jeden voxel nenáležející objektu v jejich 18-ti okolí. Pro představu nejlépe poslouží obrázek:



Obrázek 5: 18-ti okolí bodu v 3D poli

18-ti okolí O bodu F lze definovat následujícím způsobem:

$$K = [x_k, y_k, z_k] \in O : (|x_k - x_f| + |y_k - y_f| + |z_k - z_f|) \leq 2$$

$$F = [x_f, y_f, z_f]$$

Pro dvě tělesa A (reference) a B (segmentace) jsou vybrány povrchové voxely $S(A)$ a $S(B)$. Následně je pro každý voxel z $S(A)$ vybrán nejbližší voxel z $S(B)$ a uložena jeho vzdálenost. Pro výpočet vzdálenosti je použita eukleidovská norma:

$$d(a \in S(A), S(B)) = \min_{b \in S(B)} \|a - b\|$$

Celá hodnota ASD je pak dána jako součet všech těchto vzdáleností a to od prvního k druhému i od druhého k prvnímu:

$$ASD = \frac{1}{|S(A)| + |S(B)|} \left(\sum_{a \in S(A)} d(a, S(B)) + \sum_{b \in S(B)} d(b, S(A)) \right)$$

2.3.5 Kvadratický průměr vzdáleností povrchů (RMSD, root mean square symmetric surface distance)

Jedná se o téměř stejnou metriku jako v 2.3.4, pouze se počítá suma kvadrátu vzdáleností:

$$ASD = \frac{1}{|S(A)| + |S(B)|} \left(\sum_{a \in S(A)} d^2(a, S(B)) + \sum_{b \in S(B)} d^2(b, S(A)) \right)$$

2.3.6 Maximální vzdálenost povrchů (MSD, maximum symmetric surface distance)

Ze všech uložených vzdáleností z bodu 2.3.4 je vybrána největší vzdálenost od S(A) k S(B), pak největší od S(B) k S(A). Z těchto dvou vzdáleností je pak vybrána ta větší.

$$MSD = \max \left[\max_{a \in S(A)} d(a, S(B)), \max_{b \in S(B)} d(b, S(A)) \right]$$

3 Navržený způsob řešení

3.1 Představení metody, blokové schéma

Následující metoda je výsledek práce autora této práce. Jako taková se bohužel nemůže měřit s pracemi týmů odborníků využívajících větších prostředků. Na rozdíl od řady těchto prací ale jsou její popis i implementace volně přístupné veřejnosti. Metoda používá obecně známé postupy zpracování obrazu (filtrace, K-means kvantizace) a po přečtení této kapitoly by měl čtenář ovládající programovací jazyk a znalý alespoň základů zpracování digitalizovaných obrazů být schopen ji implementovat.

Metoda byla vyvíjena na dvaceti snímcích ze soutěže *Sliver07.org*. Nevyužívá žádné trénování, ani řadu moderních přístupů, které některé práce vyvíjené odborníky využívají. Odůvodnění zavržení těchto přístupů viz závěr této kapitoly. Výhodou však je, že po implementaci by měla být metoda připravená k použití.

Metoda je rozdělena do pěti bloků:



Obrázek 6: blokové schéma metody

CT snímek - je 3D snímek v Hounsfieldově škále (viz kapitola 2.1.2).

Inteligentní metoda prahování - spočívá v nalezení dolní a horní hranice za použití detekce špiček v histogramu a změn diference. Vychází ze znalostí získaných z dostupné množiny.

Filtrace prahovaného obrazu – použití maximálního, minimálního a dvou různě velkých průměrovacích filtrů. Všechny filtry mají fixní rozměry v milimetrech.

K-means odstínová kvantizace – rozdělení filtrovaného obrazu na vrstvy za použití K-means (MacQueenova) algoritmu.

Výbrání žádoucích oblastí – má obdobu v moderních přístupech (watershed – zaplavování oblastí, přístupy založené na vrstevnicích – nazývané contour či levelset) ale je mnohem hrubší a má některé další vlastnosti.

Post proces – závěrečné zpracování binárního obrazu. Skládá se hlavně z binárních

operací, cílem je odstranění prvků které v játrech nelze nalézt (díry apod.).

Následuje popis jednotlivých bloků. Na začátku každé podkapitoly jsou vždy vysvětleny obecné principy které daný blok používá. Pokud je čtenář s těmito principy obeznámen, doporučuje se mu popis principů přeskočit a přejít k diskuzi vztahu principů k této úloze a popisu implementace.

3.2 Inteligentní metoda prahování

Tato podkapitola popisuje vyvinutou metodu prahování. Na rozdíl od často používaných pevně daných hranic jsou hranice určeny analýzou histogramu.

3.2.1 Popis principu histogramu a prahování

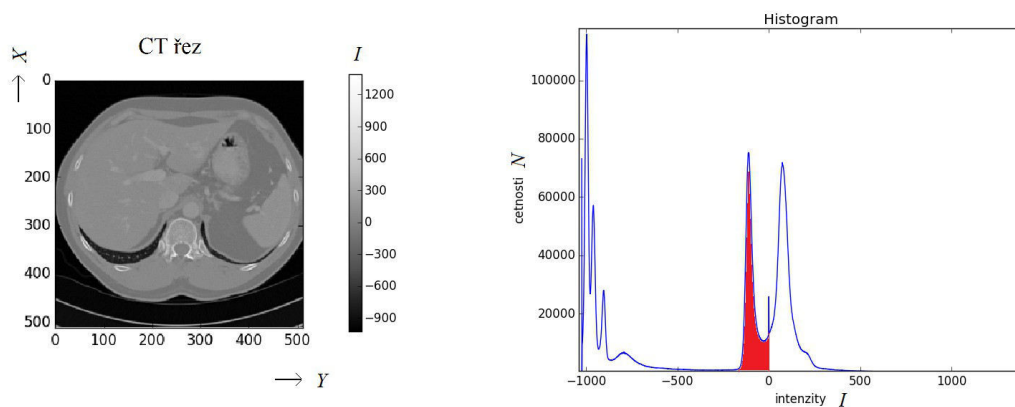
Prahování je rychlé, relativně jednoduché zpracování obrazu, jedná se o vybrání pixelů (zde voxelů) s danými intenzitami. Histogram obrazu pak je graf četností a intenzit pixelů (voxelů) v daném obrazu. Pro 3D černobílý obraz (což CT snímek je) lze vytvoření histogramu popsat jako matematické zobrazení:

$$OBR[X, Y, Z, I] \rightarrow HIST[I, N]$$

Kde četnost N odpovídající intenzitě I je suma všech voxelů $V[x,y,z,i]$ přes rozměry X, Y a Z s intenzitou rovnou I .


$$N_I = \sum_{x \in X, y \in Y, z \in Z} V[x, y, z, i]: i = I$$

Nejllepší je v tomto případě názorná ukázka, zleva doprava: jeden řez z CT v hounsfieldově škále (osa Z není vidět), histogram celého CT snímku s červeně vyznačenou vybranou oblastí:



Obrázek 7: řez CT snímku (*Sliver07.org*) a histogram snímku

Prahovaný obraz pak je binární obraz s hodnotami 0 (voxely nemají dané intenzity) a 1 (voxely mají dané intenzity, na obrázku 7 červeně vyznačeny):



Obrázek 8: prahovaný řez CT snímku


3.2.2 Diskuze prahování pro danou úlohu

Daná úloha je velmi často řešena polo-interaktivně, obvykle tak, že uživatel má za úkol několikrát kliknout dovnitř jater a vybrat tzv. seedy. Tento zdánlivě triviální úkol však musí v automatické úloze vyřešit stroj.

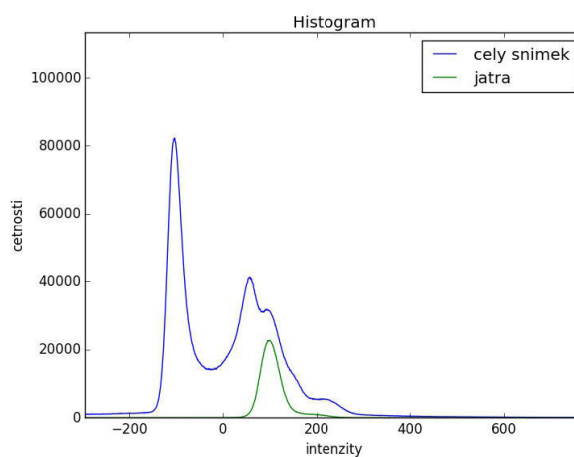
Jelikož játra mají velmi proměnlivý tvar, obsahují různé intenzity a i jejich struktura se často odlišuje, přístup založený na konvoluci s natrénovaným vzorem se nezdá jako vhodný. Obdobně pracuje i přístup založený na jazycích a detekci primitiv, kde právě detekce primitiv by nejspíš využívala konvoluci, a některé části (např. portální a dolní dutá žíla) by nejspíš bylo možné velmi úspěšně detekovat, ale z důvodu individuálně odlišné struktury jater není pro další nastavbu příliš perspektivní. Některé práce [3] používají detekci hran kolem jater, avšak tyto hrany jsou v sousedství s různými orgány různé (například kolem plic je velmi snadno detekovatelná, jinde téměř nezatelná), a v rámci daných možností se nezdálo, že tento přístup by byl v termínu uskutečnitelný, i když se zdá perspektivní.

Jelikož CT snímky používají Hounsfieldovu škálu, prahování s fixními hranicemi je v některých pracích jako nalezení výchozího bodu využíváno [4]. Po několika pokusech s fixními hranicemi se nezdál tento přístup jako vhodný, nicméně poté co byly analyzovány všechny snímky trénovací množiny a bylo upuštěno od jakéhokoli filtrování před výpočtem histogramu, byly nalezeny zákonitosti platné pro celou trénovací množinu.

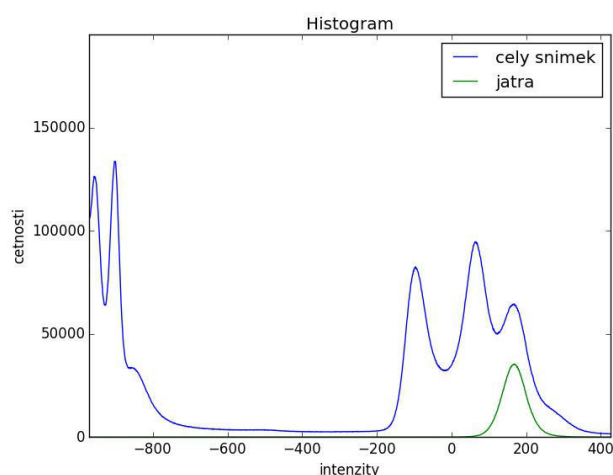
Součástí množiny byla i ruční segmentace jater, díky tomu bylo možné porovnat histogram jater a celého snímku. Oblast kde se vyskytují játra je na následujících histogramech zeleně:



a)



b)



c)

Obrázek 9: varianty uspořádání Gaussových křivek v histogramu

Analýzou celého snímku bylo zjištěno, že játra v CT snímku na histogramu tvoří nejpravější 'výraznou' Gaussovou křivku (na snímku b je vidět nevýrazná křivka – kosti a ledviny) v sumě více Gaussových křivek. Byly vymezeny případy:

- a) křivky jsou tak blízko že je nelze rozlišit
- b) lze rozlišit dvě křivky
- c) lze rozlišit tři křivky

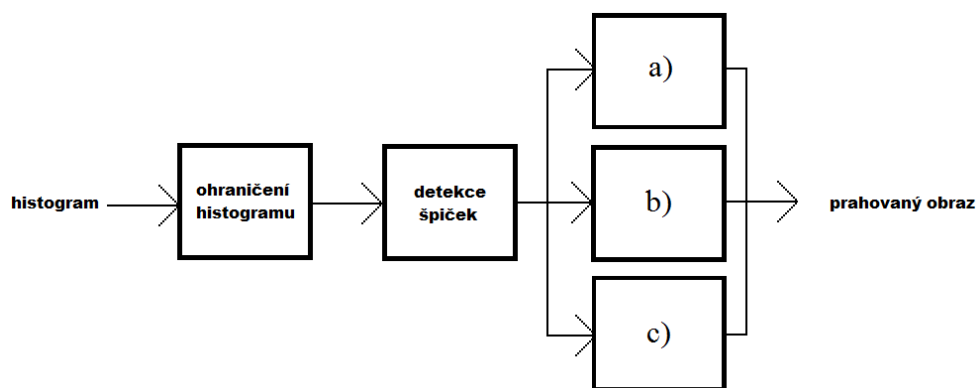
To že játra tvoří nejpravější výraznou křivku platí pro celou dostupnou množinu, bez výhrady. Lze se tedy domnívat že to bude platit obecně.

Logicky se nabízí E-M (expectation-maximization) algoritmus. Shrnutím tohoto algoritmu je, že modeluje Gaussovy křivky z daných dat. Je však třeba určit váhy jednotlivých křivek, a to je právě problém který je v tomto případě obtížně řešitelný. Mezi ukázanými variantami b) a c) je problém obzvláště patrný, neboť v b) má levá křivka výrazně větší váhu než v c), je třeba vzít také v potaz že v b) jsou křivky mnohem blíže u sebe (jsou sečteny). Výsledky experimentů s E-M algoritmem nedopadly dobře, a proto byl zavržen. Podrobnější informace o E-M algoritmu viz [10].

Místo něj byla zvolena detekce špiček a následné hledání změn v diferenci pro případy a) a b).

3.2.3 Popis inteligentní metody prahování

Blokové schéma metody prahování:



Obrázek 10: blokové schéma metody prahování


V následujících odstavcích jsou používány termíny 'zleva' a 'zprava', 'nejpravější' a podobně. Jako směr 'vlevo' je chápán vždy směr od nuly k záporným hodnotám na ose intenzit histogramu a jako 'vpravo' směr k němu opačný.

Ohraničení histogramu

Histogram je zleva ohraničen a to tak, že 200 nejnižších jasů je z histogramu odstraněno. Jedná se o velkou špičku obsahující vzduch, která pro segmentaci jater není relevantní.

Detekce špiček

Jedná se v podstatě o 'procentuální prahování histogramu'. 95% intenzit je vynulováno, a ponecháno je jen 5% nečastějších.



Obrázek 11: ukázka detekce špiček

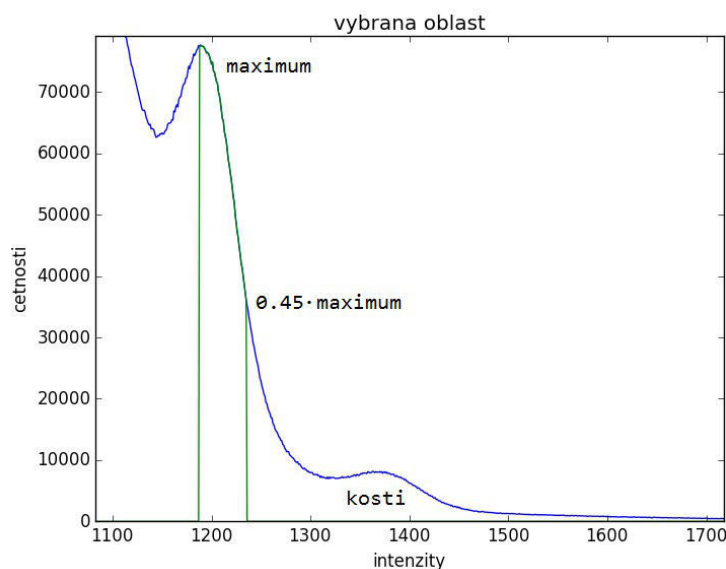
Jako špička je označena souvislá oblast neobsahující nulu. Občas se mohou při použití tohoto přístupu vyskytnout malé, "šumové" špičky. Jejich odstranění je zaručeno odebráním špiček menších než 15% šířky největší detekované špičky.

Špičky by bylo možné detekovat i jinak než je zde uvedeno, například konvolucí se vzorem, autor tento přístup již použil v jiné úloze, ale vzhledem k proměnné šíři špiček a existenci variant byl tento přístup zavržen, protože navržený funguje a odpovídá přímo variantám, neboť pro dané varianty najde daný počet špiček.

Variant a) – detekovány jsou tři špičky

Oproti zvyklostem bylo rozhodnuto započít s vysvětlením varianty c), protože je nejjednodušší, a její pochopení pomůže při a) a b).

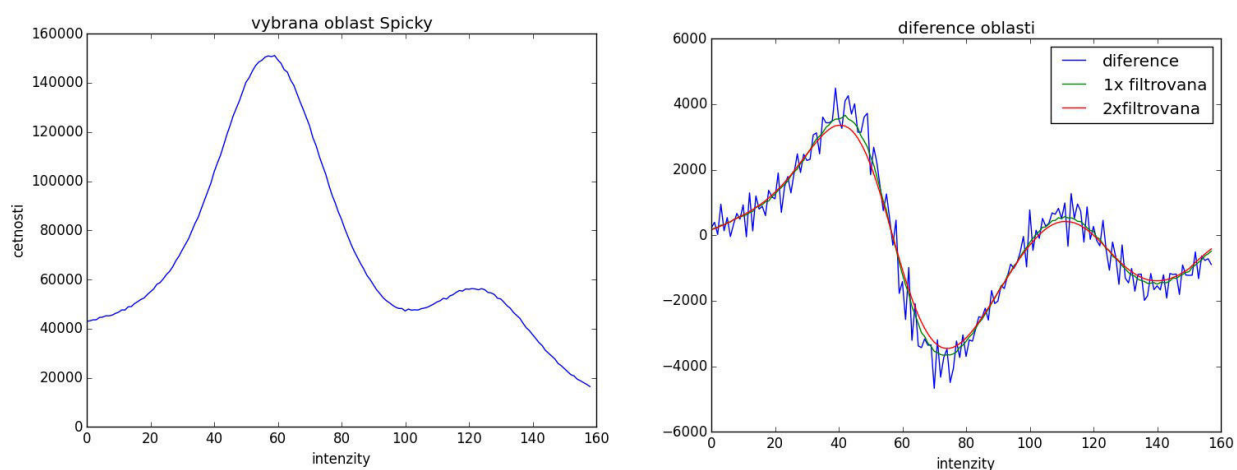
Prahování spočívá v nalezení maxima špičky, které je vybráno jako dolní (levá) hranice prahování, a v místě kde hodnoty četností poklesnou na 45% maxima je vybráno jako horní (pravá) hranice prahování. Vše je zřejmé z obrázku č. 12.



Obrázek 12: prahování pro variantu c)

Varianta b) – detekovány jsou dvě špičky

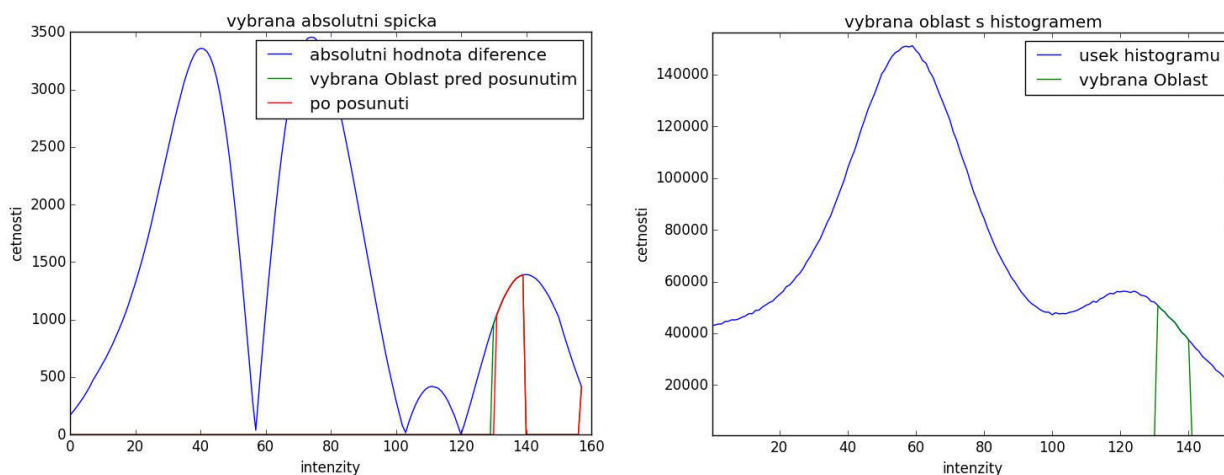
Podobně jako u prvního případu je vybrána oblast z nejpravější špičky, jen místo maxima se bere počátek špičky a jako kritérium konce 10% maxima. Tak je získána pravá část špičky. Je vypočtena její diference 1. řádu. Ta je pak dvakrát filtrována průměrovacím filtrem typu obdélník délky 15, aby došlo k jejímu vyhlazení. Filtr může být fixně 15, neboť se pohybuje po Hounsfieldově škále (která se nemění).



Obrázek 13: varianta b), vybraná oblast a její diference 1. řádu a její filtrace

Cílem je tedy vybrat nejpravější špičku ve filtrované diferenci. Z filtrované diference se vypočítá absolutní hodnota a vyberou se špičky jako v bodu detekce špiček,

jen je vynulováno 40% oblastí (jelikož to je absolutní hodnota, tak se jedná o hodnoty poblíž nuly). Jako dolní hranice je vybrán počátek špičky, jako horní hranice je vybráno maximum špičky. Výsledek je pak posunut o 15% své šířky doprava. U velkých špiček hrozí vybrání nevhodných oblastí (zde je tato operace velmi nutná), a malé špičky jsou ovlivněny jen málo (jako na obrázku).

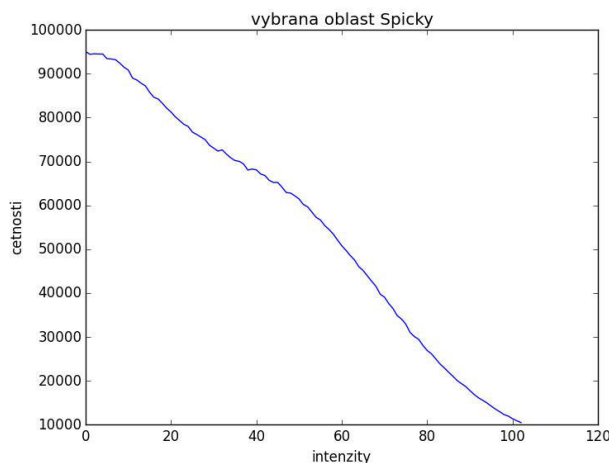


Obrázek 14: absolutní hodnota a prahování pro variantu b)

Na druhém obrázku je vidět výsledná hranice a nabízí se analogie s metodou c). U této varianty je třeba být zleva opatrnější, a zahrnout méně intenzit, protože Gaussovy křivky jsou blízko u sebe. Šířka je určena v diferenci, protože z histogramu není úplně patrná (zde by nejspíš bylo možné ji určit, avšak není to obecně pravidlem).

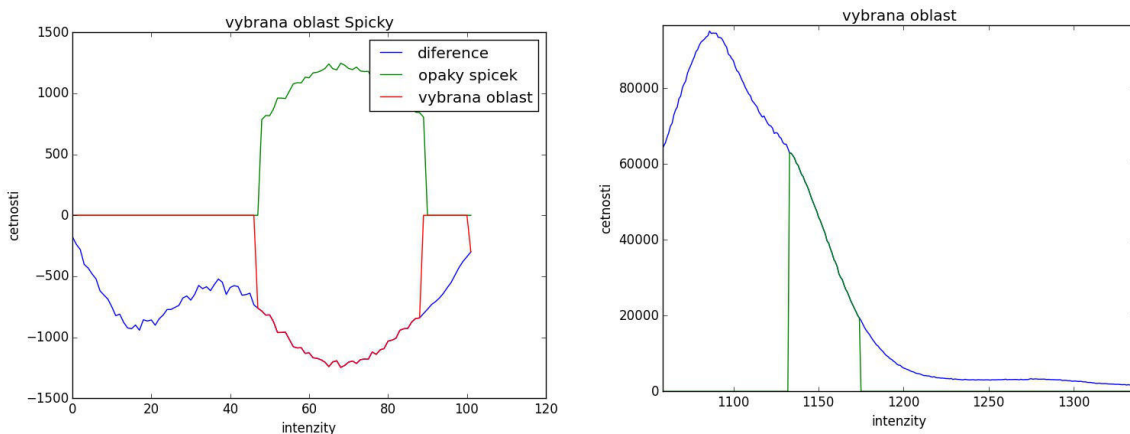
Varianta a) – detekována je jedna špička

Je zde třeba uvést, že v dostupné množině se tato varianta vyskytovala pouze jednou, a nebylo tedy možné prahování pro tuto variantu důkladně otestovat. Podobně jako v případě b), je vybrána oblast vpravo od maxima (jediné špičky). Jako počátek je zvolen bod kde křivka dosáhne 70% maxima a jako konec kde dosáhne 10% maxima. Tato varianta funguje na daném obrazu stejně i pokud je jako počátek zvoleno maximum, odstranění je zde pro případ, že se v diferenci bude vyskytovat něco, s čím není možné počítat. Z obrázku je patrná změna křivky a po uvedení variant c) a b) je zřejmé kde bude hranice nejspíš vymezena.



Obrázek 15: varianta a), vybraná oblast

Opět je spočítána diference. Jelikož je neustále záporná, a změny jsou na ní menší než v b), je filtrována stejným filtrem jako v b), ale pouze jedenkrát. Následně je obrácena (krát -1) a je nalezena její nejpravější špička.




Obrázek 16: varianta a), vybraná oblast

Opět se nabízí srovnání s variantou c), a je vidět, že výsledek jí relativně odpovídá. Jak již ale bylo řečeno, tato varianta se bohužel v dostupné množině vyskytovala pouze jednou. Nicméně, nepopírá teorii že játra jsou nejpravější 'výrazná' Gaussova křivka v histogramu.

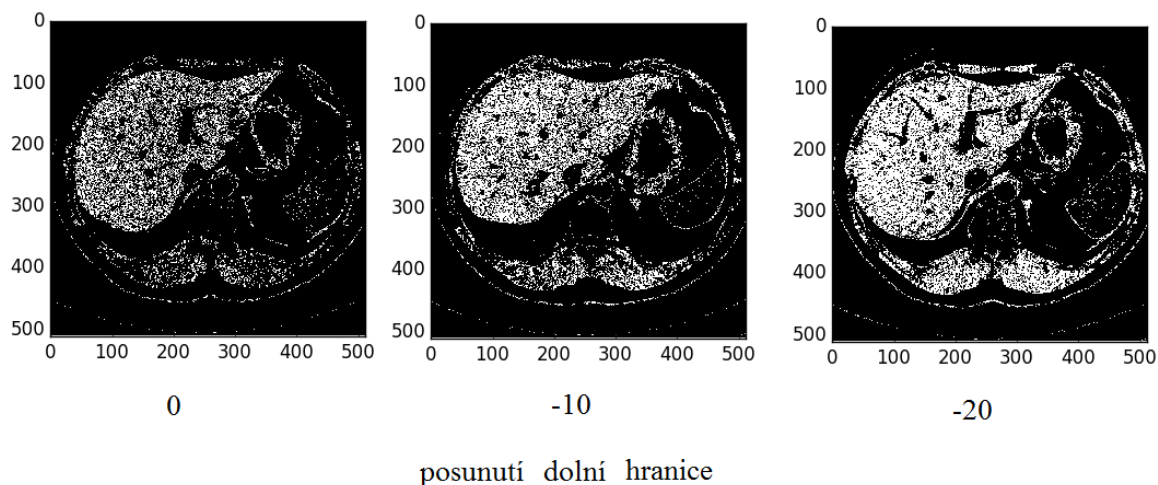
3.2.4 Ukázka výsledků, diskuze změn parametrů

Ukázka výsledků pro varianty a), b) a c) (v řezech kde se nachází játra jako největší objekt) je na obrázku 17:



Obrázek 17: výsledky prahování pro všechny varianty


Jak je patrné z obrázků, metoda podává konzistentní výsledky pro všechny tři varianty. Hranice jsou dobře patrné, je však třeba vzít v potaz, že zobrazena nejsou kritická místa kde může dojít k chybám. (diskuze k výsledkům viz kapitola 4). Z obrázků je též patrné, že jednoduchými operacemi (například binárními) požadovaného výsledku



Obrázek 18: prahování pro posuny dolní hranice

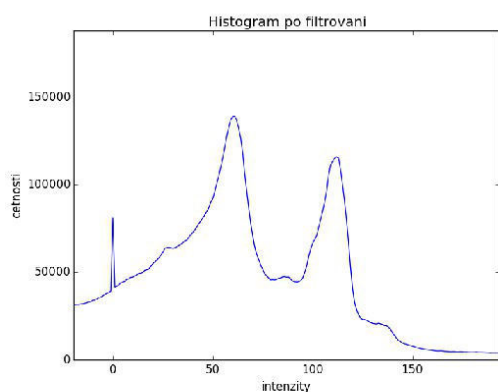
dosaženo nebude, a že je třeba sofistikovanější postup. Nicméně člověk by byl játra schopen určit a to nejspíš i pokud by nebyl odborník, a výsledek by byl velmi dobrý. Což je výrazné zlepšení oproti CT obrazu.

Z předchozího popisu jednotlivých variant prahování lze vyčíst, že snahou je vybrat pravou polovinu Gaussovy křivky jater. Také padlo tvrzení že nalevo od vrcholu Gaussovy křivky je více nežádoucích objektů. Je třeba však dodat, že na dolní straně, existují také nežádoucí objekty. Pro vytvoření představy slouží obrázky č. 18 a 19.

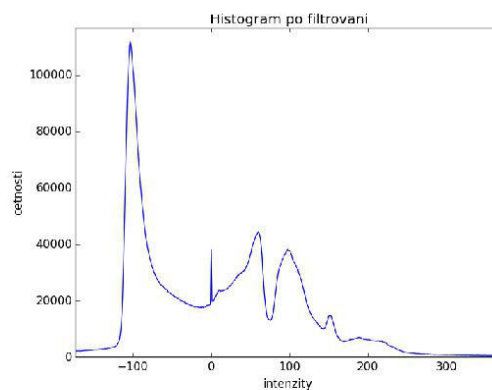


Obrázek 19: prahování pro posun horní hranice +20


S posunutou dolní hranicí prahování je logicky prahováno více jater, a ta jsou plnější. Nárůst v okolí jater je však několikanásobně vyšší, protože se nyní prahování jater vyrovná. Díry uvnitř jater nejsou zaplněny i při silném posunutí hranice (na prvních dvou snímcích nejsou tak patrné). Sousedící oblasti, které lze nazvat rizikovými (konkrétně tuk) nelze od jater ve třetím snímku odlišit.



a)



b)



c)


Obrázek 20: histogramy po filtraci

Dále je třeba zmínit, že ne ve všech snímcích dochází k úplně stejnému vývoji a že intenzita orgánů je relativní. Vzhledem k zjištěné pozici jater se lze domnívat, že orgány mají nějaké uspořádání a v CT snímku je nějaký řád, avšak nemusí se nutně vztahovat k játrům. Dále se jedná o snímek, kde panuje relativní pořádek a proto byl zvolen jako ukázkový.

Při posunu horní hranice dochází k zvýraznění mnoha orgánů. V první řadě se jedná o ledviny, které s játry sousedí a mohou vyvolat problém u mnoha metod. Dále kosti, konkrétně žebra, na stejném místě jako tuk, avšak žebra od jater dělí hrana, jak je patrné z obrázku (při porovnání s posunem dolní hranice je rozdíl jasně zřejmý). Zvýšení horní hranice není tak problematické jako té dolní, nicméně jeho přínos nepřevažuje nad potencionálním nebezpečím.

Mnoho metod používá před jakoukoli prací s obrazy filtraci. Ukázány jsou histogramy po filtraci průměrovacím filtrem o velikosti 5mm ve všech osách pro 3 varianty a), b) a c) na obrázku 20.

Informace získaná předchozím postupem není úplně ztracena, nicméně hranice mezi Gaussovými křivkami jsou mnohem méně zřejmé. Histogram však neukazuje pravý důvod zavržení předběžné filtrace:




Obrázek 21: prahování bez a s filtrací

Při filtraci dochází vždy ke ztrátě informace. Obrázek 21 je toho jasným příkladem. Při použití gaussovského filtru při prahování jsou sice nalezeny plné oblasti, ale hrany jsou na některých místech velmi nedobře poškozeny (hlavně ta v dolní části jater). Problémy s přetečením kdy je prahována část cizího orgánu (výstupek z jater) filtrace neřeší, naopak experimentování ukázalo, že tento problém filtrování před prahováním jen zhoršuje. Paradoxně pro jiné orgány (kosti, ledviny) se zdá tato operace velmi perspektivní.

Následuje pokus o vysvětlení z anatomického hlediska, od člověka bez anatomického vzdělání, za jehož absenci se omlouvá. Jedná se o osobní teorii. Lze říci, že

játra mají určitou strukturu. Vzhledem k tvrzení, že daná množina obsahuje jak snímky s kontrastní látkou, tak i bez ní, lze předpokládat část této struktury není látkou extrémně ovlivněna. Na rozdíl od tepen a žil do jater vstupujících, které mají v některých případech intenzitu mnohem vyšší než tato struktura (a jsou tedy jistě ovlivněny kontrastní látkou). Prahování podrobné snímky struktury jater připomíná. V případě že ja tato struktura poškozena či změněna, není prahováním bohužel nalezena.

Prahování tedy nenajde následující části, někdy se v požadované části nacházející: výrazné tepny a žíly, tumory. Pokud by tyto části prahováním detekovány byly, bylo by



Obrázek 22: prahování obrazu kde je nádor

nebezpečí přetečení v následujících částech vyšší než je přípustné. Navíc zdravá část jater je detekována a zdá se, že je možné tuto problematiku dodatečně řešit. Ukázka nejhoršího průběhu prahování je na obrázku 18.

3.3 Filtrace prahovaného obrazu

Filtrace v metodě slouží k úpravě prahovaného obrazu pro následující krok. Cílem je zvýraznit velké shluky avšak ponechat mezi nimi rozpoznatelné hranice.

3.3.1 Popis principu diskrétní konvoluce

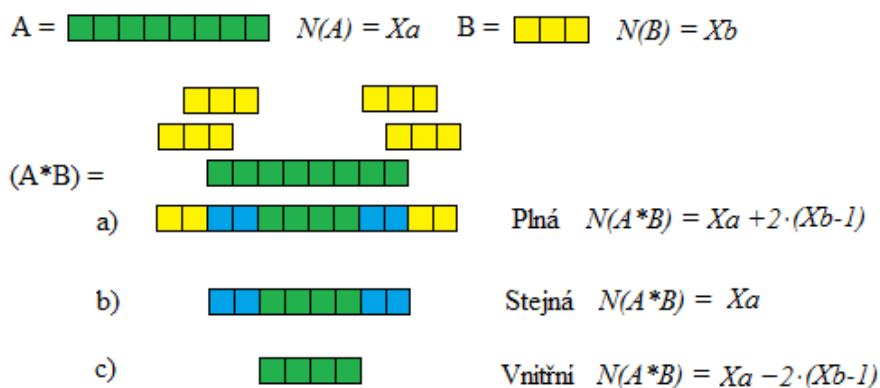
Konvoluce je matematická operace, jejíž použití lze v oblastech řízení a zpracování signálu najít téměř v každé úloze. Použití konvoluce v této konkrétní úloze je filtrace s průměrovacím filtrem. Konvoluce probíhá mezi dvěma útvary. V případě filtrace obrazu je jeden útvar obraz, a druhý útvar filtrační maska, v případě rovnoměrného filtru používající rovnoměrné rozdělení pravděpodobnosti. Jelikož v úloze je použit trojrozměrný filtr, je zde uveden trojrozměrný příklad, který na rozdíl od jedno a dvourozměrných nelze najít ve většině literatury zabývající se touto oblastí.

Definice diskrétní konečné trojrozměrné konvoluce

Konvoluce ($A*B$) mezi dvěma trojrozměrnými objekty A a B v rovinách X, Y a Z :

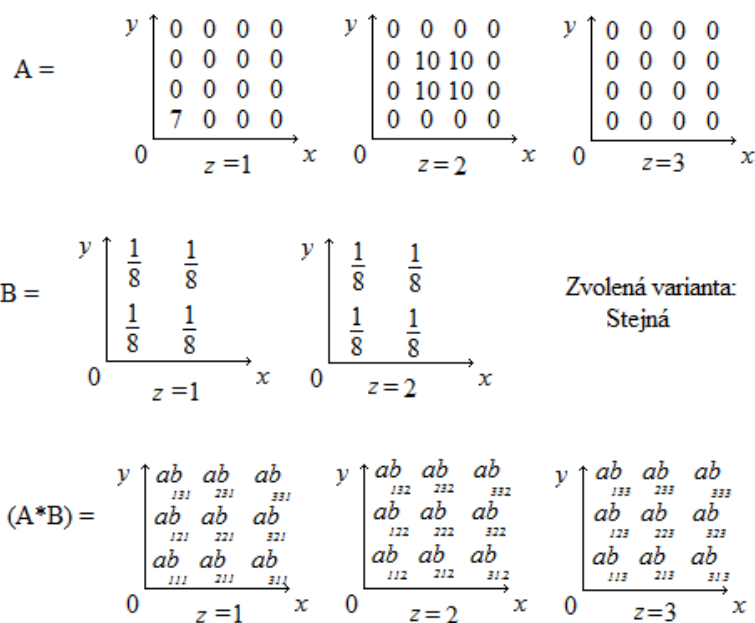
$$K(x, y, z) = \sum_{i=-l}^l \sum_{j=-m}^m \sum_{k=-n}^n A(x-i, y-j, z-k) \cdot B(i, j, k)$$

Výchozí definice konvoluce vychází ze spojitého prostoru (sumy jsou nahrazeny integrály) a nekonečných hranic. V případě této úlohy se jedná o konvoluci diskrétní a konečnou, a proto je zde uvedena pouze její definice. Výběr hranic l, m a n bývá obvykle zvolen podle toho jaká má být velikost výsledné konvoluce ($N(A*B)$). Pro vysvětlení poslouží následující ukázka pro *jednorozměrnou* (a nejvíce názornou) konvoluci:



Pro tři rozměry se aplikuje stejný princip i pro zbylé dvě osy Y a Z .

Příklad




$$\begin{aligned}
(A*B)(1,1,1) &= ab_{iii} = \sum_{i=1}^2 \sum_{j=1}^2 \sum_{k=1}^2 A(1-i, 1-j, 1-k) \cdot B(i, j, k) = \\
&\sum_{i=1}^2 \sum_{j=1}^2 A(1-i, 1-j, 1-1) \cdot B(i, j, 1) + A(1-i, 1-j, 1-2) \cdot B(i, j, 2) = \\
&\sum_{i=1}^2 A(1-i, 1-1, 0) \cdot B(i, 1, 1) + A(1-i, 1-1, -1) \cdot B(i, 1, 2) \\
&\quad + A(1-i, 1-2, 1-1) \cdot B(i, 2, 1) + A(1-i, 1-2, -1) \cdot B(i, 2, 2) = \\
&\quad A(1-1, 0, 0) \cdot B(1, 1, 1) + A(1-1, 0, -1) \cdot B(1, 1, 2) \\
&\quad + A(1-1, -1, 0) \cdot B(1, 2, 1) + A(1-1, -1, -1) \cdot B(1, 2, 2) \\
&\quad + A(1-2, 0, 0) \cdot B(2, 1, 1) + A(1-2, 0, -1) \cdot B(2, 1, 2) \\
&\quad + A(1-2, -1, 0) \cdot B(2, 2, 1) + A(1-2, -1, -1) \cdot B(2, 2, 2) = \\
&\quad + A(0,0,0) \cdot B(1,1,1) \quad + A(0,0,-1) \cdot B(1,1,2) \\
&\quad + A(0,-1,0) \cdot B(1,2,1) \quad + A(0,-1,-1) \cdot B(1,2,2) \\
&\quad + A(-1,0,0) \cdot B(2,1,1) \quad + A(-1,0,-1) \cdot B(2,1,2) \\
&\quad + A(-1,-1,0) \cdot B(2,2,1) \quad + A(-1,-1,-1) \cdot B(2,2,2) =
\end{aligned}$$

Všechny hodnoty které nejsou známy (každé A kromě (0,0,0)) jsou nahrazeny nulou:

$$\begin{aligned}
&+ 7 \cdot \frac{1}{8} && + 0 \cdot \frac{1}{8} \\
&+ 0 \cdot \frac{1}{8} && + 0 \cdot \frac{1}{8} \\
&+ 0 \cdot \frac{1}{8} && + 0 \cdot \frac{1}{8} \\
&+ 0 \cdot \frac{1}{8} && + 0 \cdot \frac{1}{8} = \frac{7}{8}
\end{aligned}$$

$$(A*B)(2,2,2) = 10 \cdot \frac{1}{8} + 0 + 0 + 0 + 0 + 0 + 0 + 7 \cdot \frac{1}{8} = \frac{17}{8}$$



Z příkladu je vidět postup konvoluční masky filtru (B) konvolvovaným obrazem (A) díky barevnému označení odpovídajících výsledků. Z příkladu je též zřejmé, že konvoluční maska se ve výpočtech s postupem filtru nemění, mění se pouze hodnoty odpovídající části obrazu. Dále je vidět že zvolený filtr (průměrovací) průměruje obraz, snižuje rozdíly mezi intenzitami, což bude na následujících obrázcích (21 a dále) možné pozorovat jako rozostření.

3.3.2 Diskuze filtrace pro danou úlohu

Vzhledem k tomu, že filtrace byla před inteligentním prahováním z důvodu zachování informace vynechána, dalo by se očekávat, že bude následovat a není třeba žádná diskuze. Není tomu však zcela jednoznačně. Je třeba si uvědomit, že získaný binární obraz představuje povětšinou jednotlivé body, a i tak by jej šlo reprezentovat. Tedy jako skupinu bodů se souřadnicemi $[x,y,z]$. Tato změna by vedla na použití shlukovacích metod. Játra by pak logicky byla určena jako "nejsilnější" shluk kdy kritéria by byla hustota bodů a velikost, kterých by tento shluk dosahoval nejvíc ze všech.

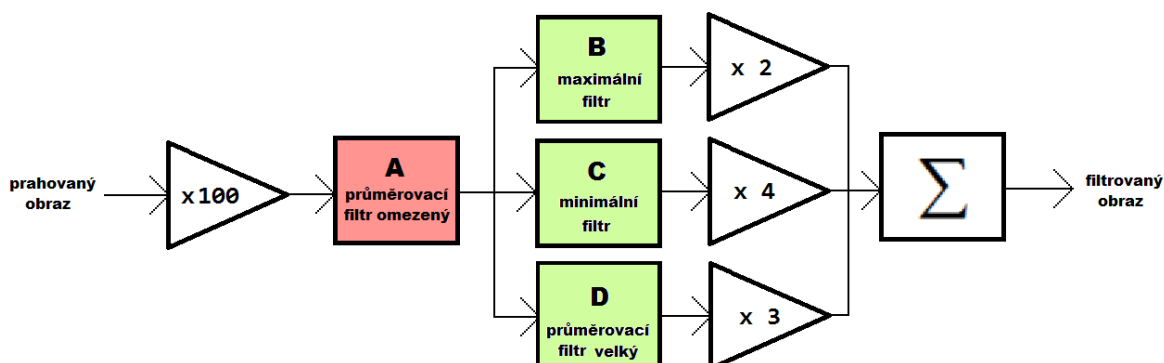
Tento přístup byl zavržen pro dvě jeho úskalí. První je existence řady "šumových" bodů které by bylo vhodné nepřičítat do žádného shluku. Filtrací lze samozřejmě řadu z nich odstranit, filtrace by však měla za následek ztrátu informace, která by mohla zhoršit průběh shlukovacího algoritmu. Druhé a hlavní úskalí, je objem dat. Tři rozměry nejsou příliš mnoho, ale bodů při rozlišení 512×512 a 71 řezech, což je nejmenší počet v dané množině je počet bodů větší než 10^7 . Nelze zaručit, že metodu nebude třeba použít na vyšší rozlišení, kde by číslo bylo řádově vyšší. Hlavní důvod zavržení tohoto přístupu je tedy časová náročnost.

Tato část algoritmu jako taková se může bez znalosti dalšího postupu zdát nahodilá, či zbytečná. Je třeba vzít v úvahu, že snahou této metody je vytvořit vhodný obraz pro další krok. Který mohl být mnohem sofistikovanější, ale moderní metody se bohužel neosvědčily a byl zvolen přístup jiný (mnohem 'brutálnější'). Jedná se o přístupy typu watershed (zaplavování oblastí) a contour (level set, vrstevnice). Cílem filtrace obrazu tak je zvýraznit oblast jater, avšak ponechat tmavší oblasti na hranicích s jinými orgány. Játra pak budou vybrána jako největší 'kopec' (ve 3D prostoru).

Tato část je tedy silně provázána s následujícím krokem a všechny parametry v ní obsažené byly určeny na základě intenzivních experimentů. Jelikož tyto experimenty prováděl jediný člověk, nelze popřít, že je dost pravděpodobné, že existuje ještě lepší nastavení parametrů pro filtraci prahovaného obrazu a zvolenou metodu. Také nelze popřít že pro výše uvedené 'jemnější' přístupy lze najít vhodnou filtraci obrazu, autorovi se to však nepodařilo. Vyzkoušení těchto přístupů je však autorem silně podporováno.

3.3.3 Popis metody filtrace prahovaného obrazu

Blokové schéma metody filtrace:

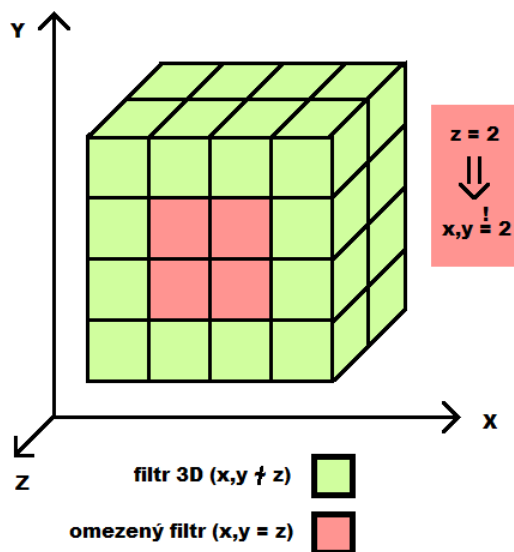


Obrázek 23: blokové schéma metody filtrace

Filtry jsou použity čtyři, označeny jsou A,B,C a D. Jsou také barevně odlišeny což je vysvětleno v následujícím odstavci, kde je popsán způsob jejich vytvoření.


Vytvoření 3D filtru

Protože program je třeba vytvořit variabilní pro různé rozlišení, je třeba filtry vytvořit v pevně daných jednotkách, které odrážejí realitu – milimetrech. Jelikož velikost voxelu je známa, vytvoří se filtr pomocí zaokrouhlení podílu jeho fixní délky a velikosti voxelu v dané ose, obě veličiny v milimetrech. Experimenty také ukázaly že i když fixní



Obrázek 24: filtr v milimetrech a omezený filtr

délka ukazuje stabilní výsledky, různá velikost rozlišení v ose Z však může způsobit problémy. Konkrétně, rozlišení v ní je horší než v osách X a Y , protože je ovlivněna rychlostí posunování CT přístroje a jinými nastavenými parametry. Pokusy s filtrem se stejným počtem jednotek voxelů v každém směru ukázaly, že se může jednat o přínos, avšak jistě se nejedná o správné řešení. Pro zachování stejnoměrnosti filtru tedy byla zvolena možnost omezení na osy X a Y , které tak mohou být maximálně tak velké jako je osa Z .



Obrázek 25: srovnání filtru bez a s omezením

Lze říci, že k informaci v osách X a Y je třeba přistupovat více opatrně, protože je vzorkována jemněji. Srozumitelnější odůvodnění však stojí na základě dalšího kroku: při použití zaplavování oblastí na ukázky z obrázku 21 by v obrázku bez omezení vznikla nejprve řada ostrůvků a poté najednou celá oblast jater, avšak s řadou nežádoucích výčnělků. V druhém obrázku bude tento proces mnohem plynulejší. Nabízí se také otázka, proč je prahovaný binární obraz násoben 100. Odpovědí je šetření paměti, protože tímto způsobem filtry pracují pouze v celočíselné oblasti (8-bitů) a dochází tak k *razantnímu* ušetření paměti.


A) průměrovací filtr malý

Jedná se o jediný filtr s omezením. Jedná se o průměrovací filtr (s rovnoměrným rozdělením) o velikosti 5mm. Jeho ukázku lze najít na obrázku 21.

B) maximální filtr

Maximální filtr nefunguje jako průměrovací, ale v dané oblasti vybere maximum a to umístí do výsledku. Velikost maximálního filtru je 4. Jeho ukázku lze najít v obrázku 22.

Slouží k zvýraznění vnitřku jater, avšak také smazává hranice mezi orgány, proto je mu ve výsledném součtu přiřazena nejnižší váha.



Obrázek 26: maximální, minimální a velký průměrovací filtr

C) minimální filtr

Minimální filtr funguje téměř stejně jako maximální, pouze vybere minimum. Velikost je 7mm. Jak je patrné z obrázku, prohlubuje hranice mezi objekty, a proto je mu přiřazena nejvyšší váha. Bohužel také silně narušuje hranice, proto musí být použit v kombinaci s ostatními filtry.

D) průměrovací filtr velký

Tento filtr slouží k tomu aby zlepšil chod v následujícím kroku a zajišťuje že játra jsou největší objekt. Díky tomu že nemá extrémně vysokou váhu, informace z předchozích dvou filtrů není ztracena.

Výsledný součet

Součet všech filtrů SUM je dán jako:

$$\text{SUM} = 2 \cdot B(A_r) + 4 \cdot C(A_r) + 3 \cdot D(A_r); \text{SUM} \in \langle 0, 900 \rangle$$


$$A_r = A(100 \cdot \text{prahovany}); A_r \in \langle 0, 100 \rangle$$

Filtrovaný obraz je tedy normalizovaný pro libovolné rozlišení.

3.3.4 Ukázka výsledků filtrace

Na obrázku 23 je ukázka váženého součtu filtrů, včetně detailů hranic jater a

různých těles která do segmentace nemají patřit. I když lidským okem se nemusí tento



Obrázek 27: součet filtrů a jeho detaily

součet zdát jako nejlepší, volba parametrů byla určena na základě experimentů, a obraz který vypadal podle člověka lépe v nich dopadl naopak hůře. Diskuze změn parametrů není provedena, protože pro danou metodu popsanou v následující kapitole byly tyto filtry v dostupném časovém horizontu vyhodnoceny jako nejlepší pro dostupnou množinu dat (bylo dosaženo nejlepších výsledků).

3.4 K-means odstínová kvantizace

3.4.1 Popis Lloydova algoritmu

Problém K-means byl poprvé takto nazván Jamesem MacQueenem. Řešení stejné úlohy v rámci kvantizace signálu v pulzně kódové modulaci formuloval Stuart Lloyd v roce 1957. Algoritmus tak bývá často označován různými názvy. Protože Lloydova práce je první, je zde též ocitována [5] a je zde nazván Lloydovým algoritmem. Na rozdíl od této původní práce však následující popis používá termíny jako *obraz* (ve smyslu vektor příznaků) a *třída* z oblasti umělé inteligence, aby na závěr mohlo být ukázáno, jak přesně se v práci algoritmus používá.

Formulace problému K-means

Mějme danu množinu vektorů příznaků dimenze u , dále obrazů X :

$$x \in X : \quad x = [x_1 \dots x_u]$$

Mějme danu skupinu v tříd (shluků) Q do které lze obrazy přiřadit:

$$Q = [Q_1 \dots Q_v]$$

$$\forall x \in X \exists Q_i: x \in Q_i$$

Klasifikátor γ je funkce, která každému obrazu přiřadí třídu (shluk):

$$\gamma: X \rightarrow Q$$

Reprezentanty $q_1 \dots q_v$ každé třídy (shluku) pak lze určit jako její hmotný střed (průměr):

$$q_v = \frac{1}{N} \sum_{k=1}^N x_k; \quad x_1 \dots x_N \in Q_v$$

$$q = [q_1 \dots q_v]$$

Aproximace y , veličiny x , za pomoci shluků Q pak bude:

$$y(x) = q_v(x)$$

Chybová funkce z mezi veličinou a její aproximací pak je:

$$z(x) = y(x) - x$$

Pokud je známa distribuční funkce veličiny x (apriorní pravděpodobnost), F , nejlepší aproximace pak lze dosáhnout minimalizací následujícího kritéria:

$$N(q) = \int_{-\infty}^{\infty} \|z(x)\|^2 dF(x)$$

Což pro známý počet shluků a obrazů a jejich přiřazení do shluků lze napsat jako:

$$N(q) = \int_{-\infty}^{\infty} \|(q(x) - x)\|^2 dF(x) = \sum_{a=1}^v \sum_{k=1}^N \|(q_a - x_k)\|^2$$

$$x_1 \dots x_k \in Q_a$$

Slovy suma přes všechny shluky, suma přes všechny obrazy ve shluku ze vzdálenosti daného obrazu od středu daného shluku.

Lloydův algoritmus

Lloydův algoritmus nezaručuje nalezení globálního minima kritériální funkce $N(q)$. Zaručuje pouze nalezení stacionárního bodu. Ten může být typu sedlo, či lokálním minimem. Může se logicky stát že globální minimum je algoritmem nalezeno. Musí být předem znám počet shluků v a množina obrazů X_2 .

Následuje popis chodu algoritmu v krocích 1 až 4.

1. je zvoleno v počátečních středů shluků q^1 , libovolně v definičním oboru X aby do nich byl přiřazen alespoň jeden bod (například náhodně zvolené body $z \in X_z$):

$$q^1 = q_1^1 \dots q_v^1 \in X$$

2. jsou vytvořeny shluky tak, že každý obraz x v množině X_z je přiřazen do shluku Q_o , k jehož středu má nejmenší vzdálenost:

$$\forall x \in X_z : x \in Q_o : \|(q_o^t - x)\|^2 = \min_{a=1 \dots v} \{ \|(q_a^t - x)\|^2 \}$$


3. Pro každý shluk je střed posunut do jeho hmotného středu, průměru ze všech bodů které v daném kroku t ve shluku jsou:

$$q_a^{t+1} = \frac{1}{N} \sum_{k=1}^N x_k; \quad x_1 \dots x_N \in Q_a^t$$

4. Pokud zastavovací kritérium není dosaženo, vrací se algoritmus zpět na krok 2. Pokud je dosaženo zastavovací kritérium, například pokles kritériální funkce $N(q)$ je menší než pevně stanovená hodnota, či bylo dosaženo daného počtu kroků t , je algoritmus ukončen a obrazy x jsou rozděleny do v shluků Q .

3.4.2 Použití Lloydova algoritmu v metodě

Lloydův algoritmus v této konkrétní metodě slouží k vytvoření 'vrstevnic'. Vektory příznaků x tak mají pouze 1 příznak, intenzitu. Cílem algoritmu je v rozmezí 0-900 najít



Obrázek 28: obrázek kvantizovaný za pomoci Lloydova algoritmu

vhodné rozdělení intenzit do jednotlivých shluků - 'vrstevnic'.

$$x \in \langle 0, 900 \rangle, u = 1, v = 14, \varepsilon = 10^{-5}, \|X_r\| = 4 \cdot 10^5$$

Algoritmus je pouštěn na množině $4 \cdot 10^5$ náhodně vybraných vzorků z filtrovaného obrazu. Zvolený počet shluků (vrstev) algoritmu je 14. Počáteční středy shluků jsou určeny jako náhodně vybrané body z množiny. Jako zastavovací podmínka je pevně daná hodnota minimálního poklesu kritériální funkce na 10^{-5} . Algoritmus je spuštěn dvacetkrát a jako výsledek vybrán ten s nejnižší kritériální funkcí.

3.4.3 Diskuze k-means vektorové kvantizace

K-means vektorová kvantizace je běžně používána pro šetření paměti při práci s 2D obrázky. Na třetí rozměr ji lze použít naprosto stejně. Rozdělení na vrstevnice je jasné a přehledné a bylo jej tak možné nastavit spolu s filtrací obrazu tak, aby podávalo konzistentní výsledky pro celou dostupnou množinu. U složitějších metod se bohužel konzistentních výsledků v daném časovém horizontu nepodařilo dosáhnout. Typickým jevem při nastavení parametrů bylo, že pro jeden vzorek z dostupné množiny metoda segmentovala příliš, a pro druhý se zastavila naopak extrémně brzy. Kromě přístupů watershed – zaplavování oblastí, z jejichž principu vytvořená metoda vychází, avšak žádnou konkrétní metodu nepoužívá (a proto zde žádná není citována) byl vyzkoušen i přístup v [6], active contour model. Nelze tvrdit, že tyto metody a přístupy nefungují, či snad že jsou nepřesné. K jejich správnému nastavení by však podle odhadu bylo potřeba více než jeden člověk a nejspíš i speciální vyhodnocovací technika, což překračuje rámec této práce. Výsledná metoda je tak dost robustní aby konzistentně fungovala na celé množině, avšak za cenu nepřesností.

3.5 Vybrání žádoucích oblastí

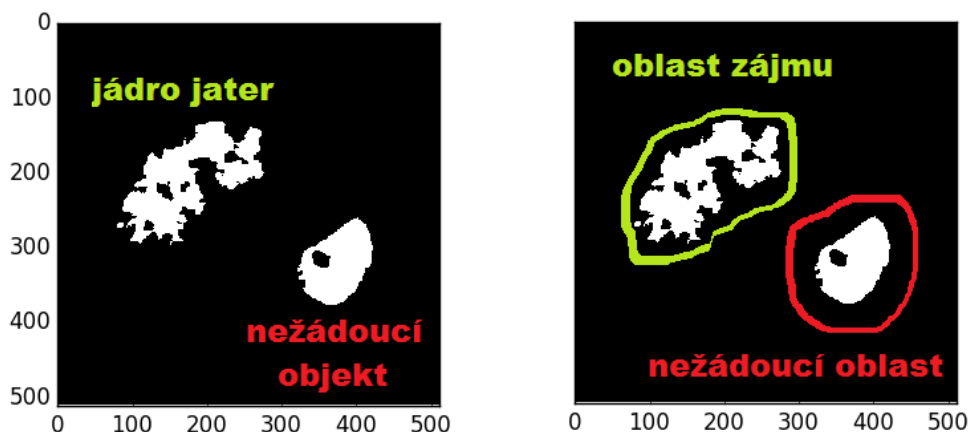
3.5.1 Popis metodiky vybrání žádoucích oblastí

Jelikož k-means kvantizace je mnohem hrubší náhrada sofistikovanějších metod, nestačí pouze vybrat největší objekt. Je třeba využít znalosti o všech nalezených útvarech a určit nežádoucí oblasti z druhé a třetí vrstvy. Popis jednotlivých kroků doplněný ilustračními obrázky následuje:

Určení 1. vrstvy

Jako 'jádro' jater je určen největší objekt první vrstvy. Pro definici sousednosti voxelů je použito 18-ti okolí (viz 2.3.4 obrázek 5). Toto 'jádro' se nachází vždy uvnitř jater, avšak nemusí jej vždy úplně rovnoměrně vyplňovat. K tomu slouží 2. vrstva. Ostatní

objekty v 1. vrstvě jsou tedy označeny jako nežádoucí.




Obrázek 29: objekty první vrstvy a oblasti 'nežádoucí' a 'zájem'

Jako žádoucí oblast je vybrána oblast 40mm kolem objektu (je třeba poznamenat že se jedná o řez z 3D snímku a tedy oblasti zde nemusí úplně odpovídat 2D objektům v řezu). Jako nežádoucí oblast je vybrána oblast 60mm kolem všech nežádoucích objektů. Tyto (a následující) hodnoty byly určeny experimentálně.

Určení 2. vrstvy

Díky znalosti žádoucí a nežádoucí oblasti je nyní možné vybrat vhodnou část z druhé vrstvy. Jelikož první vrstva není rovnoměrně rozdělená v celé oblasti jater (na obrázku č. 26 je to patrné v dolní části jater na levém obrázku) je opět nutné vybrat



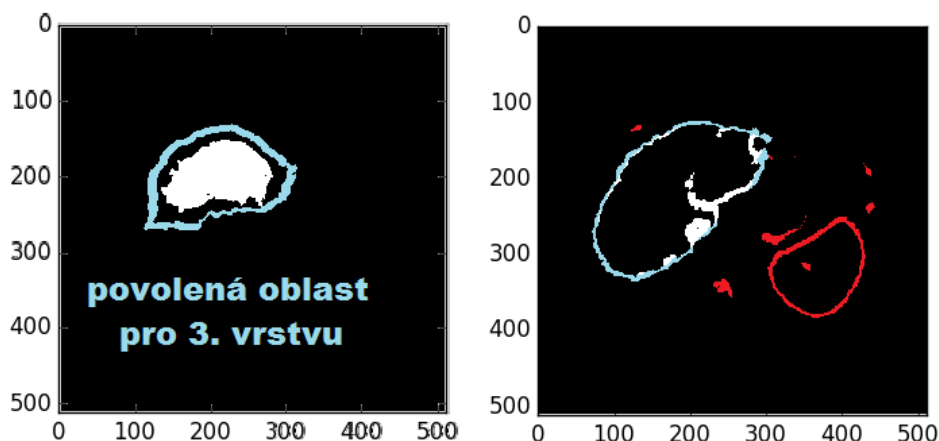
Obrázek 30: vliv oblastí na objekty druhé vrstvy

největší objekt. Sousednost objektů je stejná jako u první vrstvy, 18-ti okolí. Zde již ale může dojít k přetečení. Proto průnik daného objektu druhé vrstvy s oblastí označenou jako nežádoucí je odstraněn (první vrstva zůstává zachována). Podobně jako u první vrstvy je

opět vybrána žádoucí oblast. Před jejím vybráním je ale na objekt aplikováno binární uzavření koulí o poloměru 2mm 25x, aby se zabránilo nerovnoměrnostem. Pro popis binárního uzavření a vytvoření objektu viz následující kapitola (z důvodu přehlednosti). Oblast bude dále nazývána povolená a je do vzdálenosti 10mm od uzavřeného objektu.

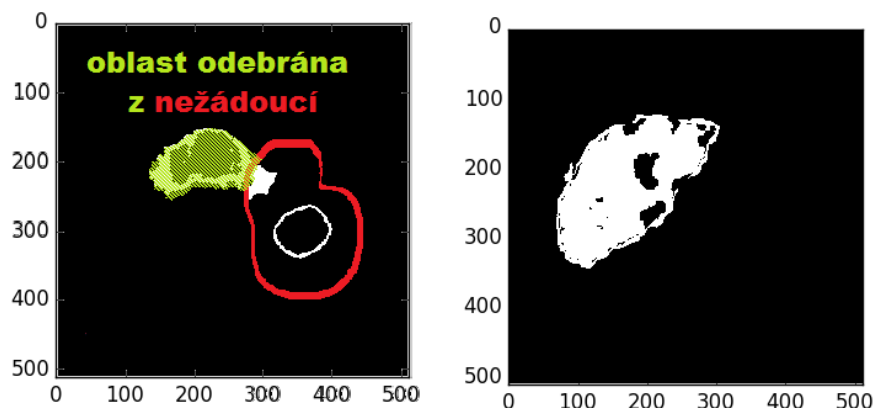
Určení 3. vrstvy

Jelikož druhá vrstva již je po objektu rozložena rovnoměrně, lze vybrat 3. vrstvu pouze v povolené oblasti.



Obrázek 31: povolená oblast a vybraná část třetí vrstvy


Aby bylo zabráněno nadsegmentaci malých nežádoucích objektů, které třetí vrstva obklopuje a jsou ve vzdálenosti 10mm od jater (např. portální žíla) jsou opět odebrány nežádoucí oblasti, avšak oblast uzavřeného objektu je z těchto nežádoucích oblastí odebrána, viz obrázek č. 28, spolu s celkovým výsledkem. Malé objekty jsou na závěr odstraněny vybráním největšího objektu se stejnou sousedností jako v předchozích krocích.



Obrázek 32: povolená oblast a výsledek vybrání oblastí

3.5.2 Diskuze metodiky vybrání žádoucích oblastí

Jak je z předchozího popisu patrné, metodika je úzce svázána s nastavením předchozího kroku, K-means odstínové kvantizace. Díky jejímu nastavení je největší souvislý objekt první vrstvy jádro jater. Drtivá většina obsahu jater se nachází ve vrstvách jedna až tři, a tak diskuze bude zaměřena hlavně na oddělení objektů.



Obrázek 33: ukázka srovnání s jinými způsoby rozdělení objektů

První se jako matematicky nejjednodušší nabízí rozdělení za pomoci rovin v trojrozměrném prostoru. Takové řešení není logicky vyhovující, protože by mohlo narušit objekt jater, jak je ukázáno na obrázku č. 29 vlevo, kde je znázorněno červeně a zvolené řešení zeleně.

I když to není na první pohled zřejmé, pravý obrázek se vztahuje k případu, kdy by celý obraz byl rozdělen na oblasti podle objektů první vrstvy. Jak již bylo řečeno, první vrstva nevyplňuje játra rovnoměrně, což by působilo problém. Další a hlavní důvod je zřejmý z obrázku: ani tato varianta nezajistí úplné odstranění nežádoucích úseků. Důvodem je že ostatní objekty jsou většinou kulovité (ledviny, srdce, slezina) a s rostoucí vzdáleností od jater vzniká rovina, která nežádoucí úsek rozděluje na polovinu, místo toho aby došlo k jeho odstranění. Zvolená varianta se také zdála přijatelnější pro následné zpracování člověkem, protože chyby obou variant byly srovnatelné, ale ty u zvolené metody se zdály mnohem lépe rozpoznatelné a snáze opravitelné člověkem.

Závěr této krátké diskuze je věnován teorii ohledně použití sofistikovanějších metod. Podle dosažených výsledků se zdá, že při použití zaplavování oblastí (watershed) by bylo vhodné segmentovat více objektů a od okamžiku kdy dojde k setkání jejich hranic přestat a označit toto místo jako rozdělení objektů (a například postupovat nějak dále). Při použití level-set metod (morphsnakes) by nejspíš bylo nutné zahrnout do kritérií algoritmu další parametry, například závislost na objemu tělesa (který je u jater relativně podobný). Pro obě metody by také byl nutný odlišný krok filtrace.

3.6 Post proces

3.6.1 Popis binárních operací dilatace, eroze a uzavření

Jedná se o operace z oblasti matematické morfologie. Zakladatelé tohoto oboru jsou George Matheron a Jean Serra. Z knihy [7] se o tomto oboru, včetně popsání metod a mnoha dalších, lze dozvědět více. V následujících ukázkách jsou příklady z dvourozměrného prostoru, kvůli názornosti. Všechny principy se přenesou do rozměru třetího a na rozdíl od konvoluce si lze jednoduché příklady v třetí dimenzi velmi snadno představit. Problematika vytvoření trojrozměrného útvaru pro operace je rozebrána dále, protože se ale týká implementace, není v této kapitole zahrnuta.

Definice dvourozměrného binárního obrazu

Mějme danu konečnou množinu A obsahující $M \times N = O$ bodů, které mohou nabývat hodnoty 0 (pozadí, v příkladech bíle) nebo 1 (objekty, v příkladech tmavě šedě).

$$A = [j_{00} \dots j_{MN}], M \cdot N = O, j \in \{0, 1\}, A(m, n) = j_{mn}$$


Binární dilatace

Operaci dilatace binárním obrazem B (maska) na obrazu A (dilatovaný obraz) lze definovat tak, že se jedná o sjednocení A s posunutými kopiemi \bar{B} obrazu B v každém místě I kde je A roven jedné.

$$A \oplus B = A \cup \bar{B}_I$$

$$I = [(q, w) \dots (e, r)]: A(I) = 1 \forall I \wedge A(Z) = 0 \forall Z \neq I$$

Ukázka na příkladu:



Mezi vlastnosti binární dilatace patří asociativnost a komutativnost:


$$A \oplus B = B \oplus A \quad (A \oplus B) \oplus C = A \oplus (B \oplus C)$$

Binární eroze

Binární erozi lze definovat jako obraz, jehož body jsou rovny jedna v každém místě odpovídající obrazu A , ve kterém kopie \bar{B} obrazu B v místě I byla podmnožinou obrazu A (body popředí se shodovaly).

$$A \ominus B = C(I) : \bar{B}_I \subset A \forall I$$


Ukázka opět na příkladu:



Binární uzavření

F násobné binární uzavření na obrazu H je F operací binární dilatace po sobě na obrazu H následované F operacemi binární eroze na dilatovaném obrazu, všechny operace s jediným společným útvarem G .

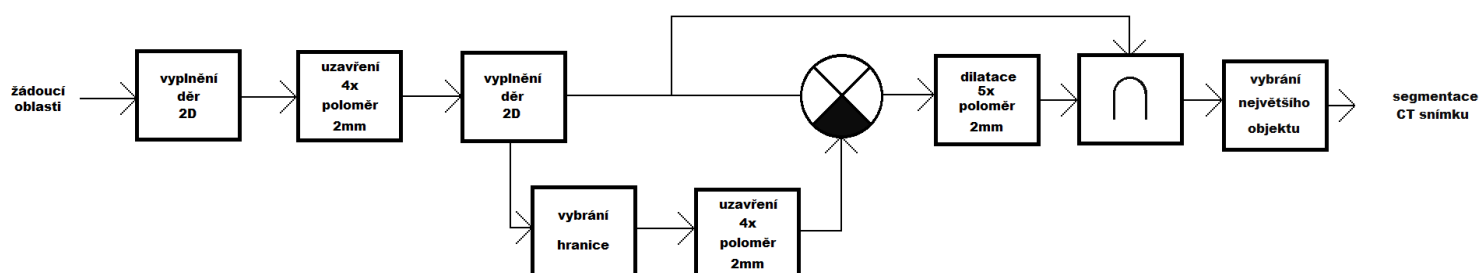
Ukázka na příkladu:



Pokud by počet operací F byl tři, byl by obraz prázdný. To je možné ošetřit zvětšením obrázku o okraj vyplněný nulami (pozadí) velikosti F krát velikost G v daném rozměru.

3.6.2 Popis metody postprocesu (závěrečného zpracování)

Blokové schéma postprocesu:




Obrázek 34: schéma metody postprocesu

Vyplnění děr 2D – jedná se vyplnění děr v 2D řezech (podél osy Z) CT snímku. Požadovaná segmentace žádné díry v řezech neobsahuje, proto je vhodné je vyplnit. Jde také o paměťovou a časovou úsporu protože operací uzavření je méně, a zlepšení přesnosti, protože příliš silné uzavření má za následek segmentaci nesprávné oblasti (dojde ke spojení laloků které se v některých případech v řezech rozdvoují).

Uzavření 4x poloměr 2mm – binární uzavření bylo definováno v kapitole 3.6.1. Zde je vysvětlen použitý způsob vytvoření binárního objektu tak, aby odpovídal reálným jednotkám pro libovolné rozlišení. Poloměr koule a počet operací viz název.

Vytvoření 3D koule v nerovnoměrně vzorkovaném prostoru




Obrázek 35: metodika vytvoření koule v 3D prostoru

Nejprve je určen "středový voxel" jehož střed reprezentuje střed koule. Kolem něj je vytvořeno pole nul. Počet voxelů v každém směru je roven poloměru dělenému velikostí voxelu v daném směru zaokrouhlenému nahoru (výsledkem je že se koule do pole vždy celá vejde). Následně se postupuje od dolního řezu v ose Z. Pomocí Pythagorovy věty (trojúhelník je z obrázku patrný) je vypočten poloměr kruhu který kouli v daném řezu reprezentuje. Každý voxel v řezu který alespoň částečně leží uvnitř kruhu je označen jako objekt (hodnota 1).

Poznámka: při operaci uzavření je nutné vytvořit kopii obrazu o větších rozměrech, konkrétně o maximální velikost koule se kterou je dilatace prováděna v každém směru.

Výplnění děr 2D (podruhé) – díky uzavření je možné že vznikly nové díry které by musel lidský operátor zaplnovat. Není tomu tak v každém případě, ale není důvod proč by tuto práci nemohl udělat počítač.

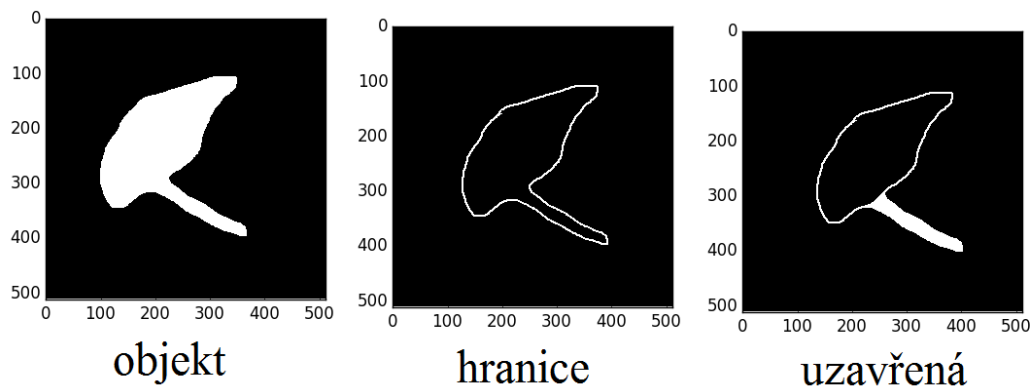


Obrázek 36: vyplnění děr

Výbrání hranice – Názvem hranice je označen povrch vyplněného a uzavřeného objektu stejně jako v 2.3.4, každý voxel který má ve svém 18-ti okolí souseda nenáležící do objektu.

Uzavření 4x poloměr 2mm (hranice) – binární uzavření hranice o celkové velikosti 8 milimetrů by z hranice mělo vytvořit dolní dutou žílu a podobné nežádoucí oblasti tenčí než 16 milimetrů, které jsou chybně segmentovány. To není na žádném z řezů v rovině Z vidět, a proto je na obrázku 33 fiktivní příklad, aby byl patrný smysl této operace.

Odečtení – uzavřené hranice od vyplněného objektu.




Obrázek 37: fiktivní příklad pro ukázání uzavření hranice

Dilatace 5x poloměr 2mm – jelikož může dojít k odstranění uzavřené hranice v blízkosti objektu, je objekt dilatován 1x více než bylo uzavření, protože vybrání hranice lze považovat za jednu vrstvu.

Průnik – průnik dilatovaného objektu a vyplněného objektu, protože dilatovaný nemusí vždy nutně vypovídat o nalezených hranicích jater.

vybrání největšího objektu – Výsledkem předchozího kroku může teoreticky být více než jeden objekt což je odůvodnění pro tento poslední krok.

Výsledkem je segmentovaný obraz. Ukázka výsledku bez značných chyb:



Obrázek 38: dobrý výsledek segmentace

4 Vyhodnocení výsledků

4.1 Jazyk Python a jeho prostředky pro zpracování trojrozměrných dat, implementace

Jelikož implementaci této práce lze považovat za její výsledek, a je implementována v programovém jazyce Python, bylo rozhodnuto o umístění této kapitoly na toto místo. Výsledná implementace je zahrnuta v projektu *LISA*, jehož hlavním strůjcem a organizátorem je pan Miroslav Jiřík, a proto je na konci této kapitoly představena.

4.1.1 Python, jeho výhody a nevýhody

Python je open-source programovací jazyk. To však není jediným důvodem jeho značné popularity. Jako jeho největší výhodou by nejspíš bylo označit jeho unikátní spojení objektově orientovaného, procedurálního a funkcionálního programování. Například v programovacím jazyku Java je pro vytvoření programu "Hello world!" třeba vytvořit třídu, což v Pythonu je nahrazeno pouhým napsáním příkazu *print*. Třídy a dědičnost v něm však lze uplatnit. Python také obsahuje interaktivní konzoli (Python interpreter) kterou lze používat podobně jako prostředí Matlab a spouštět z ní vestavěné matematické funkce či vlastní vytvořené funkce z modulů. Jako jeho poslední výhodou lze zmínit že je snadné jej propojit s některými jinými jazyky (JPython pro zmíněnou Javu a CPython pro jazyk C/C++).

Mezi jeho nevýhody patří rychlost, protože se jedná o interpretovaný jazyk, i když řada modulů byla časem optimalizována a dosahuje rychlosti jazyka C/C++. Jako další nevýhodu řada programátorů dávajících přednost jiným programovacím jazykům vidí ve vynuceném použití bílých znaků (mezer) nalevo od kódu čímž je určena jejich pozice v struktuře kódu (např. funkce a *for* cykly jsou odsazeny čtyřmi mezerami), kde například v Javě k tomuto slouží složené závorky.

4.1.2 Prostředky jazyka Python pro zpracování trojrozměrných dat

Pro jazyk Python existuje řada modulů. Modul je soubor obsahující Pythonovské definice a výroky. Balík pak může obsahovat více modulů. Je zde třeba zmínit, že i když bylo možné do programu *LISA* přidat nějaké moduly (a jeden byl skutečně přidán, i když nakonec není výslednou metodou používán) bylo logicky žádoucí využívat moduly již v *LISA* používané.

Moduly a balíky používané metodou

numpy - Bez tohoto numerického balíku se neobejde žádný program pracující s velkými

vícerozměrnými poli (což CT snímky jsou).

scipy – Konkrétní balíky ze *scipy* jsou *scipy.ndimage* pro realizaci filtrů a *scipy.cluster* pro realizaci Lloydova algoritmu.

random – tento modul je používán při náhodném generování vzorků pro Lloydův algoritmus.

io3d -Autorem tohoto modulu je Miroslav Jiřík a slouží k čtení a zapisování 3d dat ve standardu DICOM (Digital Imaging and Communications in Medicine).

Sed3 – opět dílo Miroslava Jiříka, modul slouží k prohlížení 3d dat.

Další moduly a balíky

Tyto balíky a moduly nejspíš budou z implementace pro důvod přehlednosti a úspory odstraněny. Jelikož je možné na GitHub dohledat historii, k datu 2.5.2015 je možné většinu z nich nalézt. Jedná se o sofistikované metody, které byly zkoušeny, ale bohužel nebylo možné za použití dostupných prostředků úspěšně použít. Přesto byly vyzkoušeny a proto je vhodné je zde zmínit, pokud je někdo s většími prostředky bude chtít vyzkoušet.


SimpleITK – modul pro propojení ITK (insight segmentation toolkit) s Pythonem. Jelikož je pro *Lisu* nutný, nebyl důvod jej nepoužít. Následují některé vyzkoušené metody z ITK:
sitk.ShapeDetectionLevelSetImageFilter - implementuje přístup z dokumentu [8]
sitk.ShapeDetectionLevelSetImageFilter - implementuje přístup z dokumentu [9]
sitk.ConnectedThresholdImageFilter - implementace rozrůstání oblastí (region growing)
sitk.MorphologicalWatershedFromMarkersImageFilter – implementace zaplavování oblastí (watershed)

morphsnakes – jedná se o modul implementující přístup podle dokumentu [6]. Kromě toho že se jej nepodařilo nastavit, není optimalizovaný z hledisek času a objemu dat. Narozdíl od předchozích jej proto nelze pro danou úlohu doporučit.

4.1.3 Projekt *LISA* a implementace

Projekt *LISA* (Liver Surgery Analyser Software) je vyvíjený v rámci spolupráce ZČU (Západočeské Univerzity v Plzni) FN (Fakultní Nemocnice) v Plzni a LF UK (Lékařské fakulty Univerzity Karlovy) v Plzni. Projekt je volně přístupný na GitHub:

<https://github.com/mjirik/lisa>



Obrázek 39: logo jazyka Python, projektu LISA a ukázka běhu aplikace

GitHub je služba pro distribuci a sdílení kódu. Projekt je psán hlavně v jazyce Python, přičemž používá některé další nástroje (např. Dříve zmíněné ITK). Konkrétní umístění metody v projektu je:

master/lisa/liver_segmentation.py

Implementace je tedy volně přístupná a jediné co je k jejímu získání potřeba je internetové připojení.

4.2 Výsledky experimentů

Experimenty byly provedeny dva, jeden zaměřený na úspěšnost, druhý na čas.

4.2.1 První experiment

Experiment byl prováděn na každém snímku z množiny dostupné na *Sliver07.org*. Při prvním experimentu byla metoda spuštěna pro každý snímek třikrát.

Pro vysvětlení veličin VOE, RMSD, RVD, ASD, a MSD viz kapitola 2.3. Jako těleso číslo 1 (A) je brána ruční segmentace, jako těleso číslo 2 (B) je brána segmentace strojová. Pro výpočet skóre byly váženy všechny veličiny stejně (což může být chybně, ale bohužel v [1] nejsou váhy udány). Byly přidány další veličiny, které se zdály užitečné:

V1, V2 - Objemy těles v milimetrech krychlových.

E1 - První chyba strojové segmentace, objem ruční segmentace který strojovou nebyl určen (došlo k podsegmentování) v milimetrech krychlových.

E2 - Druhá chyba strojové segmentace, objem strojové segmentace který ruční nebyl dán (došlo k přesegmentování) v milimetrech krychlových.

E1p, E2p - Chyby segmentace v procentech vztažené k průměru z objemů V1 a V2.

Sx – Prvním velkým písmenem S jsou vždy označena skóre jednotlivých veličin, přičemž výsledné skóre (průměr z těchto) je označeno jako **Score**.


Většina údajů byla zaokrouhlena na dvě desetinná místa (po výpočtech), skóre byla zaokrouhlena na celé číslo směrem dolů.

V následující tabulce jsou uvedeny průměry a směrodatné odchylky (sigma) všech veličin zaokrouhlené pro srozumitelnost na celá čísla:

	VOE	Svoe	RVD	Srvd	ASD	Sasd	RMSD	Srmsd	MSD	Smsd	V1	V2	E1	E2	E1p	E2p	SCORE
prumer	89	42	-11	47	3	22	6	24	35	53	1710218	1494681	288801	73264	16	5	38
sigma	5	21	13	32	1	20	2	21	11	14	434579	327309	242770	81572	9	5	19


Tabulka 2: průměry a směrodatné odchylky veličin

Následující grafy označované boxplot ukazují medián (čára uprostřed obdélníku), první a třetí kvartil (okraje obdélníku) a rozsah dat, tedy maximální a minimální hodnotu (čáry tvaru T označované whiskers, vousy). Grafy jsou vždy provedeny u veličin kde je možné srovnání.




Graf 1: graf procentuálních veličin (VOE, RVD, E1p, E2p)

Z tohoto grafu lze vyčíst, že RVD má největší rozptyl. To je dáno částečně tím, že bylo rozhodnuto umístit tuto hodnotu do grafu bez absolutní hodnoty. Díky tomu je vidět, že medián je záporný, tedy v průměru dochází k segmentaci menšího objemu než je ruční, avšak je možné že dojde i k opačnému jevu, jak ukazuje násobek horního kvantilu. Tomu odpovídá i fakt, že hodnota mediánu E1p (podsegmentování) je větší než hodnota mediánu E2p.



Graf 2: graf vzdálenostních veličin (ASD,RMSD,MSD)

Jak lze předpokládat, hodnota maximální vzdálenosti má největší hodnotu mediánu i rozptyl. Největší naměřená hodnota MSD během experimentu byla přibližně 72.5 mm. ASD a RMSD se pohybují do 1.5 cm což lze označit za uspokojivý výsledek.



Graf 3: graf Skóre a jeho složek


Shrnutí jednotlivých skóre metody: u VOE RVD a MSD dosahuje metoda v průměru skóre 50, lze je tedy označit za silnější stránky této metody. U ASD a RMSD v průměru 20, a bylo by možné je označit za slabší stránky metody. Výsledné skóre je tedy průměrem z těchto jednotlivých, což je z grafu patrné.

Dosažené skóre tedy je 38 ± 19 . V [1] se nachází jedna metoda s nižším skóre. Stabilita skóre je horší než průměr (průměr odchylek u popisovaných metod 12) a řadí se tak v tomto ohledu k horším. Vzhledem k použitým prostředkům je však spíše udivující že skóre není nulové a tato metoda se s těmi v dokumentu může vůbec měřit.

Zdá se také, že skóre samotné nebude pro důkladné vyhodnocení metody stačit, a to konkrétně pro hledisko následného použití v praxi. Proto je provedena obrazová analýza chyb segmentace pozorovaných během tohoto experimentu.

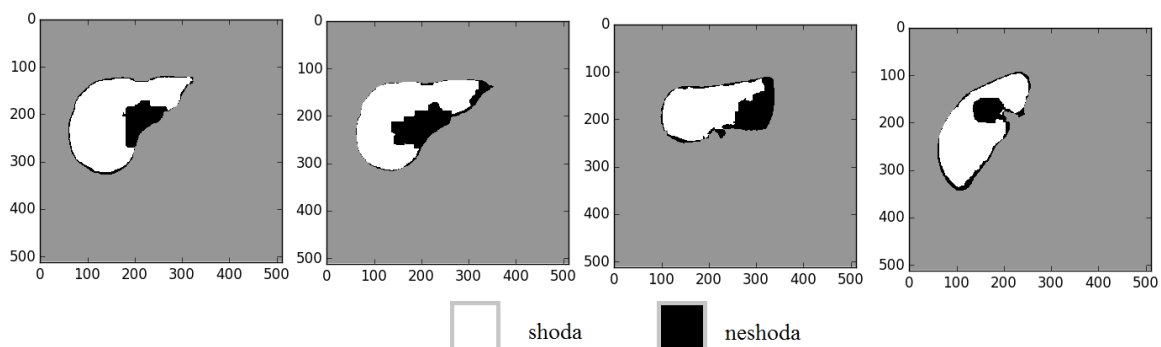
4.2.2 Analýza pozorovaných chyb

Z důvodu možnosti shlédnutí následujících obrázků i lidmi bez medicínského vzdělání bylo rozhodnuto vést následující obrázky v duchu obrázku č. 34. a v případě chyby popsat o co přesně se jedná. Zobrazení s CT snímkem a dvěma obarvenými částmi se zdálo jako příliš zmatečné, a nebyly z něj tak dobře patrné chyby segmentace. Pro lidi s medicínským vzděláním by patrně byly více přínosné, avšak ti nejspíš tento dokument nebudou číst, budou metodu pouze používat. Bylo cílem aby chyby byly lidskému oku ihned patrné, takže jsou snadno identifikovatelné na následujících obrázcích i bez CT kontextu.



Obrázek 40: podsegmentace (v rovině z)

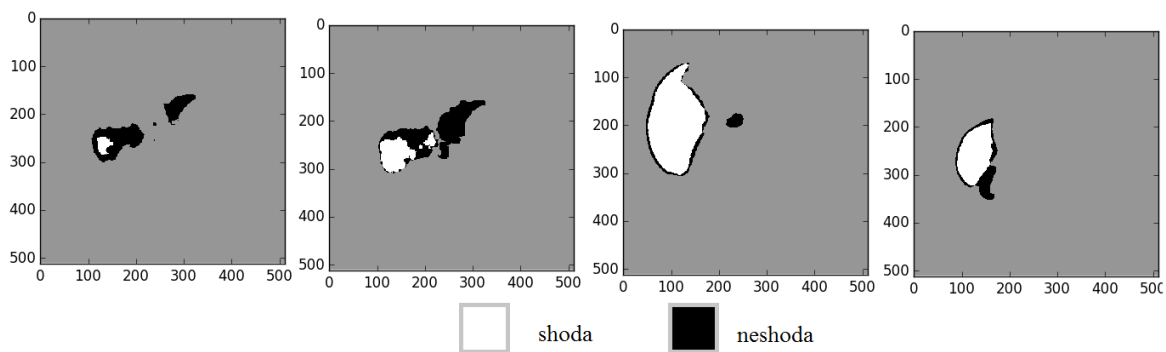
Tato chyba je nejspíše dána jinými rozměry vzorkování v jednotlivých rovinách. V drtivé většině případů při přechodu do následujícího řezu chyba buď zmizí nebo je menší. Proto i když se tyto chyby na 2D snímku zdají jako velké, ve 3D kontextu jsou srovnatelné s průběhem jinde. Z obrázku vlevo je patrné, že jejich odstranění neuváženým způsobem (binární operace) by mohlo vést k chybné segmentaci značně velké oblasti, kterou by bylo pro člověka obtížnější odstranit.



Obrázek 41: podsegmentace – cizí tělíčko

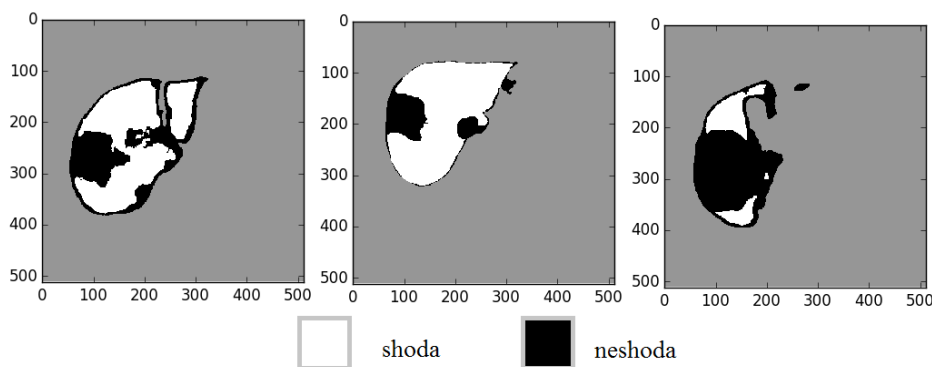
Pokud je poblíž jater nalezen cizí objekt, je vyznačena oblast kolem něj jako nežádoucí. Lze namítnout, že pokud by tyto malé objekty (často portální žíla) do segmentace zahrnuty byly, chyba by byla menší. Je třeba si však uvědomit že by tomu bylo pouze v těchto případech, zatímco u jiných dochází k nadsegmentaci, která by změnou parametrů byla neúnosná. Konkrétně zde třetí obrázek zleva je horní část jater dosedající k srdci, která je hlavním důvodem výsledného nastavení parametrů. Což vede k:

K nadsegmentaci (obr. 38) dochází hlavně v místech dotyku s nějakým orgánem. Jako nejkritičtější oblast lze z tohoto pohledu označit srdce (první a druhý obrázek zleva) v horní části jater. V některých případech bývá problém s dolní dutou žílou (třetí obrázek), pokud je segmentována příliš silně (více než skutečná). V jednom případě došlo k "dotyku" ledviny a jater, což lze označit za podobně kritický případ jaký obvykle nastává u srdce.



Obrázek 42: nadsegmentace

Na následujících obrázcích (označených číslem 39) je vidět chování segmentace pro případy kdy se v játrech vyskytuje nádor (tumor). Ten lze velmi obecně charakterizovat jako tmavou oblast. Jedná se však o netriviální problém. Díky získaným poznatkům se zdá, že lepší řešení než hledat tyto oblasti společně se zdravou tkání je hledat je sekundárně, po nalezení zdravé tkáně. Problematika nadsegmentace u těchto oblastí by nejspíš byla stejná nebo horší než u jater, což překračuje rámec této práce. Navíc v dostupné množině není dostatek snímků tohoto typu (vyobrazeny všechny 3) aby jí bylo možné z tohoto hlediska považovat za relevantní. Pokud by tedy tumory detekovány byly, mohla by být zhoršena segmentace na snímcích bez nich a platnost programu pro data mimo dostupnou množinu ohrožena. Výsledná metoda tak na těchto snímcích dosahuje nejhorších skóre.



Obrázek 43: nejhorší případy - tumory

Shrnutí obrazové analýzy

Vzhledem k tomu že zobrazené jsou pouze chybové řezy snímku a kromě posledního případu (obrázek 39) většinou zasahují pouze do několika řezů a lze je tedy považovat za nekritické. Tomu skóre odpovídá.

Novým zjištěním z obrazové analýzy je, že řadu chyb by bylo možné odvodit

pouze z tvaru segmentace, (čistě z bílé oblasti, konkrétně obrázky č. 37 a 38, obvyklé nezanedbatelné chyby) což bylo záměrem. Ostatní chyby jsou buď kritické (39) (ale chovají se velmi podobně), nebo v 3D kontextu zanedbatelné (36).

4.2.3 Druhý experiment – časová náročnost


Druhý experiment se týká časového hlediska a výpočetní náročnosti úlohy. Experiment byl prováděn na zdrojovém kódu (.py), na následující sestavě:

Windows 7 64-bit
Intel Core i5 CPU M340 2.27GHz (2x)
4,0 GB RAM

Čas běhu metody je obecně vztažen k mnoha hlediskům, z nichž sestava je pouze jedno z nich. Další je logicky objem dat. Jelikož v množině byly vždy snímky se stejným rozlišením v ose X a Y a to 512x512, lišil se pouze počet voxelů v ose Z . Ten je vypsán v následující tabulce a grafu. Programy byly spouštěny třikrát, bohužel pouze pro jednu dostupnou soustavu. Získané výsledky tak snad poslouží k orientačnímu odhadu běhu na jiné soustavě a datech.

Počet řezů	64	145	210	251
Časy (s)	123.944272046 123.944394778 119.681384977	131.191234773 131.085359314 133.126459988	176.839565031 172.067703139 173.459786528	188.136524905 188.760193762 181.845215677

Tabulka 3: měřený čas



Graf 4: měřený čas a aproximace

Čas tedy zdá se roste kvadraticky s rostoucím objemem dat. Neroste však na takovou míru, aby bylo zvaženo převzorkování na menší rozlišení. Pokud čas v praxi činí problém, úloha převzorkování je triviální. Nebylo však pro metodu vyzkoušeno. Dostupná množina k tomu totiž není dostačující (rozlišení proměnné pouze v 1 rovině a ještě v nedostatečných rádech). Ve srovnání s ostatními v [1] se zdá velmi rychlá, avšak je třeba vzít v úvahu, že tyto metody byly spouštěny na jiných (i když srovnatelných) sestavách.

4.2.4 Diskuze vlivu změny rozlišení

Jak bylo řečeno, dostupná množina k posouzení vlivu významných změn rozlišení není dostatečná. Je možné z ní vytvořit horší rozlišení. Není pravděpodobné, že by tento jev v nemocnici nastal, avšak výsledek je stejný jako průměrování původního obrazu s průměrovacím filtrem fixní velikosti. Z rozdílu mezi tímto a dostupným pak lze odhadnout vliv zvýšení rozlišení na metodu. Následuje popis vlivu na jednotlivé složky:

Inteligentní metoda prahování – Z obrázku 20 je patrné, že špičky jsou zachovány, avšak nezdaří se jako Gaussovské křivky. Nabízí se analogie s měřením náhodné veličiny, kdy při použití vyššího rozlišení (obrázek 9) se rozdělení pravděpodobnosti měření více blíží rozdělení veličiny. Obrázek 20 se nápadně podobá měření veličin s Gaussovským rozdělením s přítomností šumu či nedostatečným počtem vzorků. Lze tedy předpokládat, že při vyšším rozlišení budou zákonitosti (a hlavně Gaussovské křivky) zachovány. Lze také logicky počítat se zachováním Hounsfieldovy škály.

Filtrace prahovaného obrazu – Všechny filtry mají fixní rozměry v milimetrech. Nejsou tedy na rozlišení závislé.

K-means odstínová kvantizace – Není také na rozlišení závislá.

Vybrání žádoucích oblastí – Využívá vzdálenosti v milimetrech. Není tedy také na rozlišení závislé.

Post proces – Všechny koule mají pevný poloměr v milimetrech. Není tedy na rozlišení také závislý.

Shrnutím je že kromě prvního bloku jsou na rozlišení bloky nezávislé, a první má k němu vztah typický pro zpracovávání měřené veličiny, tedy čím lepší je měření (rozlišení je větší), tím lepší lze očekávat výsledek.

4.2.5 Srovnání s metodou Graph-Cut

Navržená metodika hodnocení je uplatnitelná i pro *interaktivní* metody (viz [1]).

Výsledky metody Graph-Cut viz tabulka 4.

Test case	VOE [%]	Scr	VD [%]	Scr	AvgD [mm]	Scr	RMSD [mm]	Scr	MaxD [mm]	Scr	Total Scr
1	11.53	55.0	-5.79	69.2	1.94	51.5	3.68	48.9	32.11	57.8	56.4
2	11.76	54.1	-4.33	76.9	1.53	61.7	2.10	70.9	15.95	79.0	68.5
3	9.47	63.0	0.29	98.5	2.32	42.1	5.45	24.3	55.51	27.0	51.0
4	9.89	61.4	1.61	91.4	1.74	56.4	2.68	62.8	23.06	69.7	68.3
5	10.12	60.5	-5.58	70.3	1.91	52.1	3.22	55.2	28.99	61.9	60.0
6	11.83	53.8	-5.38	71.4	1.96	51.1	3.47	51.8	30.91	59.3	57.5
7	7.86	69.3	-4.25	77.4	1.15	71.2	2.17	69.8	20.62	72.9	72.1
8	9.50	62.9	-6.45	65.7	1.67	58.2	3.38	53.1	39.83	47.6	57.5
9	13.93	45.6	-11.03	41.3	1.92	52.0	3.45	52.1	27.74	63.5	50.9
10	9.83	61.6	-4.30	77.1	1.42	64.5	2.20	69.4	20.38	73.2	69.2
Avg	10.57	58.7	-4.52	73.9	1.76	56.1	3.18	55.8	29.51	61.2	61.1

Tabulka 4: skóre metody Graph-Cut (*sliver07.org*)

Tedy metoda Graph-Cut dosahuje v průměru většího skóre o dvacet bodů a neselhává (skóre menší než dvacet). Je však nutné vzít v potaz že metoda Graph-Cut je *interaktivní* a vyvinutá metoda je *automatická*. Pro představu funkce metody Graph-Cut může posloužit video [11]. Vyjádřeno slovy, lékař označuje dobré a špatné oblasti. Míra interakce je značná.

Vyvinutá metoda nemůže aspirovat na plné nahrazení člověka, neboť k dosažení takového výsledku nebyl dostatečný prostor. Lékař tedy automatickou metodu spustí a bude ji následně opravovat. K srovnání skóre po opravě lékařem bohužel nejsou k dispozici statisticky významná data. Jelikož hodnoty skóre jsou relativně srovnatelné, a oprava lékařem může skóre pouze (razantně) zvýšit, hlavním ukazatelem která metoda bude používána by tak byl *čas*. Tato hodnota bohužel v tabulce přítomna není, i když je pro srovnání metod z praktického hlediska nejdůležitější.

Orientační čas doby interakce u metody Graph-Cut je přibližně 5 minut. Toto číslo není ničím podložené. Pro srovnání je proveden naprosto nepodložený odhad, a to sice že oprava bude provedena u "dobrých snímků" do půl minuty (obrázek 34), u průměrných snímků do jeden a půl minuty (obrázky 37 a 38) a u problémových snímků do čtyř minut (obrázek 39, pesimistický odhad). Odhad vychází z obrazové analýzy chyb (4.2.2). Pokud je odhad pravdivý bude doba interakce kratší než s metodou Graph-Cut, avšak celkový čas je také závislý na sestavě na pracovišti. Bude-li sestava stejně či více výkonná než ve druhém experimentu (pravděpodobný odhad, běh méně než 2-3 minuty), bude metoda nejspíš používána. Pokud bude sestava extrémně výkonná či bude provedena časová optimalizace programu a běh se podaří snížit do půl minuty, bude časová úspora nezanedbatelná. Pokud bude sestava horší, metoda Graph-Cut pravděpodobně vyjde jako lepší.


Popsaný odhad je naprosto nepodložený a hrubý. Bude tedy vhodné nechat

hodnocení na lékařích samotných. Čas ukáže, zda-li budou tuto metodu používat. Bylo záměrem během celé doby vývoje aby metoda byla co nejrychlejší a vzniklé chyby bylo možné co nejlépe opravit, i na úkor finálního skóre.

4.2.6 Možnosti použití metody pro MRI

U CT snímků jsou používána CT čísla (hounsfieldova škála). U MRI snímků se hodnoty čísel odvíjí od jednotlivých přístrojů a jejich parametrů. Relativní uspořádání orgánů v histogramu pak může být různé podle zvoleného zobrazení (např. T1). Jelikož byla analyzována množina CT a nikoliv MRI snímků, metodu pro MRI nelze použít.

Je patrné, že popisovaná metoda segmentace z CT snímků naplňuje rozsah této



Obrázek 44: CT (Sliver07.org) a MRI T1 snímek (www.healthcare.siemens.com/)

práce. Vývoj další podobné metody by tak byl bohužel nad její rámec. Mohlo by se zdát že tomu tak není, že segmentace z MRI a CT snímků je podobná a stačilo by metodu pouze upravit. Není tomu tak. Pro pochopení rozdílnosti problému poslouží obrázek č. 40. Jedná se o velmi odlišný problém z hlediska zpracování obrazu, i když anatomický problém je stejný. Navíc je to odlišný problém i z hlediska obecné platnosti. Nebylo by nejspíš v rámci daných možností zaručit že metoda bude fungovat i po změně parametrů přístroje. Metoda pro CT se tak jeví v tomto ohledu mnohem užitečnější.

Ze získaných poznatků pak lze nabýt dojmu, že pro obecné použití u MRI budou vhodné *interaktivní* metody, kde uživatel eliminuje právě velmi obtížně řešitelnou problematiku s nastavením přístroje a jeho parametrů. Z obrázku lze nabýt dojmu že pouhé kliknutí dovnitř jater a použití přístupu rozrůstání oblastí (region-growing) nastavené uživatelem by přineslo rychle požadovaný výsledek.

Vývoj plně automatických metod které budou zaručeně fungovat i při změně parametrů přístroje (obecně pro všechny přístroje) se jeví jako extrémně obtížný, i když není neřešitelný. Jako velmi vhodné by se po vyřešení problému obecné platnosti nejspíš ukázaly hranové přístupy, poněvadž MRI má velmi dobrý kontrast mezi měkkými tkáněmi. Což ukazuje že se jedná o přesný opak problémů řešených v případě CT.

5 Závěr

V počátku se práce zabývá nastíněním principů CT a MRI, dále pak popisem úskali řešeného problému a metodiky vyhodnocení z [1]. Následně podrobně popisuje vyvinutou metodu pro segmentaci jater z CT snímků, včetně diskuze jiných přístupů a variant. Dále popisuje způsob její implementace a použité prostředky v jazyce Python.

Výsledné skóre ukazuje, že metoda dosahuje výsledků srovnatelných s horšími automatickými metodami z [1]. Výsledky měření času ukazují že metoda je rychlejší než většina hodnocených metod.

V metodě existuje prostor pro zlepšení. První část, inteligentní metoda prahování se zdá vhodně robustní, avšak následná kombinace filtrace a hlavně výběr oblastí založený na přístupu zaplavování oblastí (watershed) je robustní příliš, tedy nastavená tak, aby podávala konzistentní, i když hrubší výsledky. Následné části metody pak na ni navazují.

I přes značný prostor pro zlepšení v této oblasti, vyplývá z dosaženého skóre, měření času a hlavně podrobné obrazové analýzy výsledků, že metoda je i přes to užitečná a tedy použitý teoretický přístup se tak jeví jako správný.

Automatická metoda dosahuje průměrného skóre 38, interaktivní Graph-Cut 61. Oprava lékařem může skóre pouze zvýšit. Z hlediska uplatnění v praxi je tak podstatné pomocí které metody lze dosáhnout požadovaného výsledku rychleji. Jelikož u obou metod je ve výsledku silně přítomen lidský faktor, statisticky relevantní data bohužel nejsou k dispozici. Učiněný odhad tak není ničím podložený a může být mylný. Odhad tvrdí že metoda bude lepší než Graph-Cut, pokud sestava na pracovišti zaručí kratší nebo stejný čas běhu metody jako při testování.

Na práci je možné navázat několika způsoby. Již zmíněná možnost vylepšení metody se však nejeví v akademickém prostředí jako pravděpodobná. Sekundární detekce tmavých oblastí se zdá mnohem příhodnější, avšak za předpokladu že bude získáno více relevantních snímků. Navázání v jiném oboru je také možné, konkrétně časová optimalizace programu, pravděpodobně realizace v jiném programovacím jazyku.

Tuto práci věnuji všem lidem kteří zachraňují lidské životy.

Literatura

- [1] Tobias Heimann a další. *Comparison and Evaluation of Methods for Liver Segmentation From CT Datasets*, IEEE transactions on medical imaging, vol. 28, no. 8, august 2009.
- [2] Nekula Josef, Heřman Miroslav, Vomáčka Jaroslav, Köcher Martin. *Radiologie*, 3. vyd. Olomouc, Univerzita Palackého v Olomouci, 2005. Dotisk 2008. ISBN 978-80-244-1011-7. S. 205. (cs)
- [3] Haibin Ling, S. Kevin Zhou, Yefeng Zheng, Bogdan Georgescu, Michael Suehling, Dorin Comaniciu *Hierarchical, Learning-based Automatic Liver Segmentation*, Integrated Data Systems Department Siemens Corporate Research, USA, Siemens Medical Solutions Germany
- [4] Lazsló Ruskó, *Hierarchical, Learning-based Automatic Liver Segmentation*, University of Szeged Department of Image Processing and Computer Graphics
- [5] Lloyd P. Stuart, *Least Squares Quantization in PCM*, IEEE TRANSACTIONS ON INFORMATION THEORY, VOL. IT-28, NO. 2, MARCH 1982
- [6] P. Márquez-Neila, L. Baumela, L. Álvarez, *A morphological approach to curvature-based evolution of curves and surfaces*. IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI), 2013.
- [7] Serra Jean, *Image Analysis and Mathematical Morphology*, Academic Press, New-York, 1982.
- [8] Malladi Ravikanth , Sethian A. James, Vemuri C. Baba, *Shape modeling with front propagation: A level set approach*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995.
- [9] Caselles Vincent, Kimmel Ron, Guillermo Sapiro, *Geodesic Active Contours*, International Journal of Computer Vision 22(1), 61–79 (1997)
- [10] A. P. Dempster; N. M. Laird; D. B. Rubin, *Maximum Likelihood from Incomplete Data via the EM Algorithm*, Journal of the Royal Statistical Society. Series B (Methodological), Vol. 39, No. 1. (1977), pp.1-38.
- [11] <https://www.youtube.com/watch?v=1gKAObj8HRc>

[12] <http://sliver07.org/>

Seznam obrázků

Obrázek 1: generace CT	3
Obrázek 2: CT snímek a voxel	4
Obrázek 3: Princip MRI	5
Obrázek 4: časy T1 a T2	6
Obrázek 5: 18-ti okolí bodu v 3D poli	8
Obrázek 6: blokové schéma metody	10
Obrázek 7: řez CT snímku (Sliver07.org) a histogram snímku	11
Obrázek 8: prahovaný řez CT snímku	12
Obrázek 9: varianty uspořádání Gaussových křivek v histogramu	13
Obrázek 10: blokové schéma metody prahování	14
Obrázek 11: ukázka detekce špiček	15
Obrázek 12: prahování pro variantu c)	16
Obrázek 13: varianta b), vybraná oblast a její diference 1. řádu a její filtrace	16
Obrázek 14: absolutní hodnota a prahování pro variantu b)	17
Obrázek 15: varianta a), vybraná oblast	18
Obrázek 16: varianta a), vybraná oblast	18
Obrázek 17: výsledky prahování pro všechny varianty	19
Obrázek 18: prahování pro posuny dolní hranice	19
Obrázek 19: prahování pro posun horní hranice +20	20
Obrázek 20: histogramy po filtraci	20
Obrázek 21: prahování bez a s filtrací	21
Obrázek 22: prahování obrazu kde je nádor	22
Obrázek 23: blokové schéma metody filtrace	26
Obrázek 24: filtr v milimetrech a omezený filtr	26
Obrázek 25: srovnání filtru bez a s omezením	27
Obrázek 26: maximální, minimální a velký průměrovací filtr	28
Obrázek 27: součet filtrů a jeho detaily	29
Obrázek 28: obrázek kvantizovaný za pomoci Lloydova algoritmu	31
Obrázek 29: objekty první vrstvy a oblasti 'nežádoucí' a 'zájem'	33
Obrázek 30: vliv oblastí na objekty druhé vrstvy	33
Obrázek 31: povolená oblast a vybraná část třetí vrstvy	34
Obrázek 32: povolená oblast a výsledek vybrání oblastí	34
Obrázek 33: ukázka srovnání s jinými způsoby rozdělení objektů	35
Obrázek 34: schéma metody postprocesu	38
Obrázek 35: metodika vytvoření koule v 3D prostoru	38
Obrázek 36: vyplnění děr	39
Obrázek 37: fiktivní příklad pro ukázání uzavření hranice	40
Obrázek 38: dobrý výsledek segmentace	40
Obrázek 39: logo jazyka Python, projektu LISA a ukázka běhu aplikace	43

Obrázek 40: podsegmentace (v rovině z)	47
Obrázek 41: podsegmentace – cizí tělísko	48
Obrázek 42: nadsegmentace	48
Obrázek 43: nejhorší případy - tumory	49
Obrázek 44: CT (Sliver07.org) a MRI T1 snímek (www.healthcare.siemens.com/)	52