


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

CHARAKTERIZACE TKÁNÍ VE SPEKTRÁLNÍCH CT DATECH

TISSUE CHARACTERISATION IN SPECTRAL CT DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Veronika Poláková

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Roman Jakubíček

BRNO 2019

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Veronika Poláková

ID: 191656

Ročník: 3

Akademický rok: 2018/19

NÁZEV TÉMATU:

Charakterizace tkání ve spektrálních CT datech

POKyny PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou zobrazování pomocí CT modality se zaměřením na možnosti dvojenergetického a spektrálního (sCT) snímání. 2) Proveďte literární rešerši o sCT. Seznamte se s dostupnými daty, jejich formátem a možnostmi jednotlivých parametrických obrazů. 3) Navrhněte vhodnou metodiku charakterizace vybraných tkání a její způsob zhodnocení. 4) Vytvořte databázi ručně nebo poloautomaticky segmentovaných vybraných tkání. Proveďte základní statistické vyhodnocení jejich CT čísel napříč spektrem energií. 5) Proveďte statistické zhodnocení výsledků pro možnosti klasifikace jednotlivých tkání na základě monoenergetických obrazů. 6) Diskutujte dosažené výsledky a možnosti využití spektrálního CT pro zpracování a analýzu medicínských dat.

DOPORUČENÁ LITERATURA:

[1] MCCOLLOUGH, Cynthia H., et al. Dual-and multi-energy CT: principles, technical approaches, and clinical applications. *Radiology*, 2015, 276.3: 637-653.

[2] DOERNER, Jonas, et al. Image quality evaluation of dual-layer spectral detector CT of the chest and comparison with conventional CT imaging. *European journal of radiology*, 2017, 93: 52-58.

Termín zadání: 4.2.2019

Termín odevzdání: 24.5.2019

Vedoucí práce: Ing. Roman Jakubíček

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

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

ABSTRAKT

Tato bakalářská práce se zabývá charakterizací tkání na virtuálních monoenergetických obrazech (VMI). Byla zpracována literární rešerše o spektrálním CT, díky kterému lze VMI vytvořit. Dále bylo provedeno statistické vyhodnocení CT čísel tkání napříč spektrem energií VMI. Bylo zjištěno, že medián CT čísla s rostoucí energií VMI roste, nebo klesá různě strmě v závislosti na tkáni. To přispívá k lepšímu kontrastnímu rozlišení vybraných dvojic tkání na vhodných VMI a tím pádem i jejich lepší segmentaci a klasifikaci na těchto obrazech.

KLÍČOVÁ SLOVA

Spektrální CT (Dual-Energy CT, Multi-Energy CT), segmentace obrazu, databáze, popisná statistika, velikost účinku, náhodný les

ABSTRACT

This bachelor thesis deals with tissue characterisation in virtual monoenergetic images (VMI). Firstly, literature survey presents spectral CT which allows reconstructing VMI. Secondly, statistical evaluation of tissue CT numbers was made for all energies of VMI which were reconstructed. It was found that with growing energy of VMI CT number increases or decreases with different steepness depending on a type of tissue. As a consequence, the suitable VMI offer better contrast resolution between selected pairs of tissues, which enables better tissue segmentation and classification in these images.

KEYWORDS

Spectral CT (Dual-Energy CT, Multi-Energy CT), image segmentation, database, descriptive statistics, effect size, Random Forest

POLÁKOVÁ, Veronika. *Charakterizace tkání ve spektrálních CT datech*. Brno, 2019, 69 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Roman Jakubíček

PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Charakterizace tkání ve spektrálních CT datech“ jsem vypracovala samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

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

Brno

.....

podpis autorky

PODĚKOVÁNÍ

Ráda bych poděkovala vedoucímu bakalářské práce panu Ing. Romanu Jakubíčkoví za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci. Dále bych chtěla poděkovat své rodině za podporu po celou dobu studia.

Obsah

Úvod	10
1 Rentgenové záření	11
2 Výpočetní tomografie	13
2.1 Dual-Energy CT	15
2.1.1 Konstrukce DECT	16
2.1.2 Basis material decomposition (BMD)	21
2.1.3 Využití v diagnostice	23
2.2 Multi-Energy CT	24
2.2.1 Konstrukce MECT	24
2.2.2 Využití v diagnostice	27
3 Přehled segmentačních metod	29
3.1 Prahování	29
3.2 Narůstání oblastí	29
3.3 Aktivní kontury	30
3.4 Morfologické operace	32
4 Statistika a klasifikace	33
4.1 Velikost účinku	33
4.2 ROC křivka	34
4.3 Náhodný les	34
5 Dostupná data a metodika	36
5.1 Dostupná data	36
5.2 Rekonstrukce parametrických obrazů	36
5.3 Metodika charakterizace tkání	37
6 Segmentace a sběr dat	38
6.1 Segmentace tkání	38
6.1.1 Segmentace měkkých tkání	40
6.1.2 Segmentace kostních tkání	41
6.2 Sběr dat a jejich uložení do databáze	43
7 Charakterizace tkání	46
8 Klasifikace tkání	50

9	Diskuze	56
10	Závěr	58
	Literatura	59
	Seznam symbolů, veličin a zkratk	64
	Seznam příloh	65
A	Klasfikace na základě samotných pixelů	66
A.1	Velký bederní sval / meziobratlová ploténka	66
A.2	Tepenná krev / žilní krev	66
A.3	Mícha / koňský ohon	67
A.4	Játra / ledvina	67
A.5	Kompaktní kost / spongiózní kost	68
B	Obsah přiloženého CD	69

Seznam obrázků

1.1	Rozdíl mezi polyenergetickým a monoenergetickým spektrem	12
2.1	Rozdíl mezi axiálním a helikálním skenováním	14
2.2	DECT – hlavní idea	16
2.3	TwinBeam DECT	19
2.4	Dual-layer DECT	20
2.5	Konstrukce spektrálních systémů	21
2.6	Basis Material Decomposition	23
2.7	Rozdělení energetického spektra do 6 binů	25
2.8	Schéma fungování photon-counting detektoru	26
2.9	Využití MECT pro detekci více kontrastních látek	28
3.1	Explicitní a implicitní vyjádření kontury	31
3.2	Přístup Chan-Vese algoritmu k minimalizaci energie modelu kontury .	31
5.1	Rekonstrukce VMI	37
6.1	Objasnění způsobu sběru dat	38
6.2	Nutnost sběru dat ze 3D masky	39
6.3	Schéma postupu při segmentaci	39
6.4	Zlepšení výběru dané tkáně erozí masky	40
6.5	Segmentace měkkých tkání	42
6.6	Segmentace kostních tkání	43
6.7	Tabulka načtených objemů dat	44
6.8	Návrh databáze	45
7.1	Charakterizace vybrané dvojice tkání	47
7.2	ROC křivky vybraných dvojic tkání	49
8.1	Různé průběhy charakteristiky tkání	51
8.2	Klasifikace pomocí mediánu regionu pixelů	53
8.3	Limitace klasifikace na základě regionu pixelů	53
8.4	Klasifikace pomocí samotných pixelů, regionu pixelů a kombinovaného přístupu	54
8.5	Postup při klasifikaci na základě kombinovaného přístupu	55
9.1	Důležitost malého poloměru kruhového okolí	57
A.1	Klasifikace pomocí samotných pixelů – velký bederní sval / meziobratlová ploténka	66
A.2	Klasifikace pomocí samotných pixelů – tepenná krev / žilní krev	66
A.3	Klasifikace pomocí samotných pixelů – mícha / koňský ohon	67
A.4	Klasifikace pomocí samotných pixelů – játra / ledvina	67
A.5	Klasifikace pomocí samotných pixelů – kompaktní kost / spongiózní kost	68

Seznam tabulek

1.1	Srovnání fotoelektrického jevu a Comptonova rozptylu	12
4.1	Velikosti účinku	33
4.2	Matice záměn	34
7.1	Cohenovo d pro vybranou dvojici tkání u daného pacienta	47
7.2	Průměrné Cohenovo d pro vybranou dvojici tkání	48
8.1	Úspěšnost klasifikace na základě samotných pixelů	51
8.2	Úspěšnost klasifikace na základě mediánu regionu pixelů	52

Úvod

Výpočetní tomografie (CT) je jedna ze základních zobrazovacích modalit současnosti. Výhodou CT je rychlá akvizice dat, naopak nevýhodou je zátěž pacienta radiačním zářením a horší kontrastní rozlišení měkkých tkání. Obě negativa se snaží výzkum řešit, přičemž tato práce se zaměřuje pouze na druhý problém.

Špatné kontrastní rozlišení tkání na obraze je zapříčiněno jejich podobným lineárním součinitelem útlumu μ při dané energii [13, 15]. Tento součinitel je závislý jak na tkáni, kterou rentgenové záření prochází, tak na energii tohoto záření [8, s. 44]. Proto pokud použijeme více energií rentgenového záření, získáme o útlumových vlastnostech jednotlivých tkání více informací, které by nám je mohly pomoci rozlišit. V roce 2006 technologický pokrok umožnil zrealizovat myšlenku pocházející již z roku 1973 o využití dvou různých energetických spekter rentgenového záření při zobrazování – byla sestavena první generace Dual-Energy CT (DECT) [11, 15]. Od této doby se technologie DECT stále vylepšují a pracuje se i na vývoji Multi-Energy CT (MECT) systémů, které by umožňovali využívat více než dvě energetická spektra. Spektrální CT (sCT) je obecně systém, který dokáže rozlišit více energetických spekter. MECT lze s určitostí označit za spektrální CT, s DECT už to je složitější. V některých případech (např. [17, 31]) se pojem sCT volně zaměňuje s pojmem Dual-Energy CT, jelikož už tato modalita dokáže rozlišit více než jedno energetické spektrum. V jiných případech (např. [13, 16]) je sCT vnímáno až jako pokročilejší systém, který dokáže rozlišit více než dvě energetická spektra rentgenového záření. Tato práce se drží prvního názoru, tudíž sCT chápe jako souhrnné označení pro DECT a MECT.

Spektrální CT nabízí vytvořit množství virtuálních (uměle dopočítaných) obrazů, které mohou napomáhat při diagnostice. Tato práce se zaměřovala na tzv. virtuální monoenergetické obrazy (VMI), které simulují, jak by obraz vypadal při průchodu RTG záření pouze o jedné energii [12, 15, 31]. Charakterizace tkání pomocí CT čísel na těchto obrazech nám může zodpovědět otázku, zda některé VMI poskytují lepší kontrastní rozlišení daných tkání než obrazy z klasického CT. Pokud by tomu tak bylo, mohou nám tyto obrazy dopomoci ke snadnější klasifikaci tkání i jejich segmentaci, která je nyní problematická z důvodu podobných CT čísel jednotlivých tkání.

1 Rentgenové záření

Rentgenové (RTG) záření je forma elektromagnetického záření široce používaná v radiologii. Vytváří se za pomoci rentgenky, kde elektrony produkované žhavenou katodou jsou díky přiloženému napětí urychlovány směrem k anodě. Během své cesty získávají elektrony kinetickou energii, kterou ve většině případů předají anodě ve formě tepla, nicméně asi 1 % se přemění na RTG záření. Terčák, na který elektrony dopadají, se většinou volí z wolframu.

Nutno si uvědomit, že současné rentgenky nedokážou vyrobit záření charakterizované pouze jednou energií. Výsledné spektrum je totiž superpozicí spojitého spektra brzdného záření („bremsstrahlung“) a diskrétních spektrálních čar charakteristického záření. Brzdné záření je dáno interakcí letícího elektronu s atomovým jádrem materiálu anody. Elektron díky pozitivně nabitému jádru změní směr a je „zbržděn“, přičemž dojde k vyzáření brzdného záření o energii odpovídající rozdílu kinetické energie před a po interakci. Kinetická energie elektronu je přitom dána napětím přiloženým mezi katodou a anodou. Charakteristické záření vzniká interakcí letícího elektronu s elektronovým obalem materiálu anody, kdy dochází k vyražení elektronu v jedné ze slupek. To vede k zaplňování volného místa elektrony z vyšších slupek, přičemž se uvolňuje energie ve formě záření. Z rentgenky tedy vystupuje polyenergetické spektrum RTG záření, jehož útlum po průchodu objektem detekujeme. Virtuální monoenergetické obrazy, kterými se tato práce zabývala, naopak demonstrují průchod RTG svazku o jedné energii [12, 15, 31]. Srovnání polyenergetického a monoenergetického spektra je uvedeno na Obr. 1.1.

Útlum svazku RTG záření o dané energii v hmotě udává lineární součinitel útlumu μ (cm^{-1}) a tloušťka vrstvy x (cm), kterou záření prochází. Celý vztah vyjadřuje rov. 1.1, kde N_0 je počet fotonů dopadajícího záření a N je počet fotonů, které prošly bez interakce.

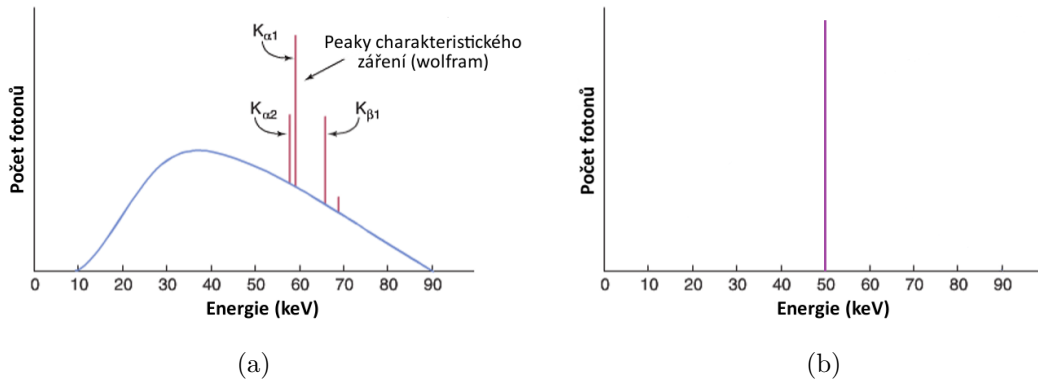
$$N = N_0 \cdot e^{-\mu x} \quad (1.1)$$

Mezi hlavní interakce RTG záření s tkáněmi pacienta patří fotoelektrický jev a Comptonův rozptyl. Rozdíl mezi nimi popisuje Tab. 1.1. Vliv Rayleighova rozptylu je považován za zanedbatelný. Celkový lineární součinitel útlumu je dán součtem útlumů pro jednotlivé interakce [8, s. 46–47].

Obecně jsou tkáně struktury buněk o podobné funkci, přičemž se dělí na epitelové, pojivové, svalové, trofické a nervové. V radiologii lze však chápat tkáně i odlišným způsobem a to jako struktury (tvořené buď několika buňkami, celým orgánem nebo daným materiálem), které podobně zeslabují RTG záření. Je pak na nás, abychom radiologické tkáně správně vyhodnotili i anatomicky. ICRU¹ roz-

¹International Commission on Radiation Units and Measurements

děluje tkáň radiologicky na čtyři základní skupiny: měkká tkáň, kostní tkáň, kontrastní látky a kovové implantáty [17, s. 8]. Tato práce je v dělení konkrétnější. Můžete se v ní tak setkat s názvy tkání jako ledvina, játra (dle ICRU patří do měkkých tkání), kompaktní kost, spongiózní kost (dle ICRU patří do kostních tkání), apod.



Obr. 1.1: Rozdíl mezi polyenergetickým (a) [8, s. 176] a monoenergetickým spektrem (b). Polyenergetické spektrum, které rentgenka běžně produkuje sestává z brzdného záření (modře) a charakteristického záření (červeně). Brzdné záření je na obrázku již filtrováno od fotonů s nízkou energií. Je patrné, že bylo použito anodové napětí 90 kV, jelikož záření větší než 90 keV není produkováno. 90 keV odpovídá úplnému zbrždění elektronu, kdy jeho veškerá kinetická energie byla vyzářena ve formě záření. Peaky charakteristického záření jsou označeny písmenem K (elektron vyražen ze slupky K) s indexy α (přechod elektronu ze sousedící slupky) či β (přechod elektronu z jiné než sousedící slupky) a jsou vždy typické pro daný prvek (zde wolfram). Obrázek (b) ukazuje spektrum, které dnešní rentgenky nedokážou vyprodukovat. Jedná se o monoenergetické spektrum, zde pro 50 keV.

Fotoelektrický jev	Comptonův rozptyl
Foton veškerou svou energii předá elektronu a zanikne.	Foton část své energie předá elektronu a změni směr šíření.
Dominantní při nižších energiích fotonu.	Dominantní při středních energiích fotonu.
Pravděpodobnost vzniku této interakce je velmi závislá na atomovém čísle prvku. Závislost je úměrná Z^3	Pravděpodobnost vzniku této interakce nezávisí tak na atomovém čísle prvku jako na elektronové hustotě prvku. Závislost je úměrná Z .

Tab. 1.1: Srovnání fotoelektrického jevu a Comptonova rozptylu.

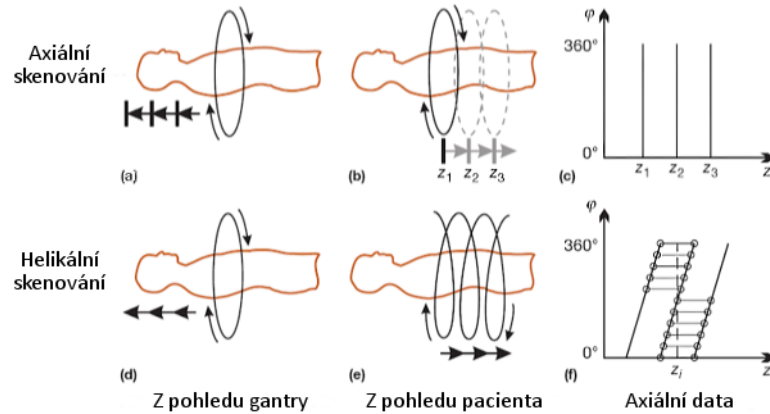
2 Výpočetní tomografie

Výpočetní tomografie (CT – „computed tomography“), též někdy zvaná jako počítačová tomografie, je zobrazovací metoda dostupná již od počátku 70. let 20. století [29] [8, s. 6]. Její vznik umožnil nástup počítačů, které byly schopny provádět rozsáhlé výpočty pro rekonstrukci dat do jednotlivých řezů [8, s. 6–7]. Na rozdíl od klasických RTG systémů se tedy neprovádí sumační zobrazení, ale tomografické¹.

Základním prvkem CT je gantry kruhovitěho tvaru s otvorem, do kterého zajíždí ve směru osy z pacient ležící na patientském stole. Uvnitř gantry je rotační část, na kterou je v současných klasických CT systémech připevněna rentgenka a pole detektorů. Je to tzv. třetí generace CT systémů, zvaná též rotace-rotace díky tomu, že rotuje rentgenka i pole detektorů. Tato generace se stala široce používanou díky technologii „slip-ring“, která umožňuje eliminovat kabelážové spojení mezi stacionární částí gantry a rotační částí. Provádí to prostřednictvím stacionárních třecích kartáčků, které klouzají („slip“) po pohybujiících se vodivých prstencích („ring“). Díky této technologii může být provedena plynulá rotace o 360° , což bylo předtím limitováno navíjením kabelů [8, s. 312–374]. Plynulá rotace jednak urychluje sběr dat, jednak umožňuje helikální skenování (též známé jako spirální), které dnes převládá nad axiálním skenováním (též známé jako konvenční [18]) zejména z důvodu rychlejšího vyšetření [5, s. 12][18, s. 24]. Rozdíl mezi skenovacími módy popisuje Obr. 2.1.

Rentgenka pro CT musí zvládat produkovat RTG záření po mnohem delší dobu, než je tomu u klasického rentgenu. Proto je kladen větší důraz na její dobré tepelné vlastnosti, které zabrání jejímu zničení. Z toho důvodu se používají buď rentgenky s rotační anodou, nebo rentgenky, které rotují jako celek. Proud elektronů z katody u obou designů nedopadá stále na jedno místo anody, což anodu tepelně méně zatěžuje a je umožněno účinnější chlazení [8, s. 180]. RTG záření se dále filtruje od neúčinných složek a kolimuje tak, aby se vybral kuželovitý vějíř rentgenového záření („cone beam“), který prosvítí scénu, tedy část pacienta. Míra útlumu RTG záření je zaznamenána polem detektorů, v současných systémech je rozšířená nepřímá konverze RTG záření na elektrický signál. Zároveň se využívá technologie vícevrstevných detektorů (tzv. MDCT), což znamená, že v ose z je více detektorů. To umožňuje rychlejší sken a tvorbu tenčích řezů. Nicméně čím tenčí řez, tím méně fotonů RTG záření se na něm podílelo, a proto se více projevuje šum. V praxi se volí kompromis mezi prostorovým rozlišením v ose z a kontrastním rozlišením. Výhodou MDCT je, že detektory mohou být používány individuálně, ale mohou být i kombinovány, čímž vzniká možnost volby mezi oběma rozlišeními [8, s. 316–335].

¹ *Tomos* znamená řecky řez.



Obr. 2.1: Rozdíl mezi axiálním (horní řádek) a helikálním (dolní řádek) módem skenování [7, s. 76]. U axiálního skenu je pacientský stůl vždy v určité poloze a po naskenování daného řezu se posouvá na další pozici ve směru osy z (b). V rámci tohoto posunu gantry nekoná pohyb (a) a neprodukuje se RTG záření [8, s. 336]. Nasnímaná data pro každý úhel natočení gantry leží v daném řezu (c). U helikálního skenování se koná kontinuální pohyb gantry (d) i pacientského stolu (e), což vytváří helikální objem dat. Tato data nemůžou být přímo použita pro rekonstrukci [5, s. 12][14, s. 421], jelikož rekonstrukční algoritmy počítají s pohybem soustavy rentgenka-detektor kolem pacienta po kruhové trajektorii a ne po šroubovicové, jak naznačuje (e). Nejjednodušším způsobem, jak získat informace v požadovaném řezu z , je interpolovat data z různých helikálních úseků (f).

Princip CT zobrazování je založen na snímání jednotlivých projekcí pod určitým úhlem natočení soustavy rentgenka-detektor. Každý bod obrazu má určitou hodnotu lineárního součinitele útlumu, kterou neznáme, nicméně známe součet (obecněji integrál) těchto hodnot přes dráhu jednotlivých rentgenových paprsků [14, s. 423]. Tyto projekce se běžně ukládají ve formě sinogramu, který nese informace o třech parametrech – na jedné ose je evidován úhel natočení soustavy, na druhé ose je pozice detektoru a šedotónovou škálou je vyjádřena hodnota lineárního součinitele útlumu, která byla naměřena přes dráhu rentgenového paprsku dopadajícího na daný detektor [5, s. 11]. Pokud máme projekcí dostatek (u CT akvizic běžně 1000 projekcí [8, s. 357]), lze z nich poměrně věrně rekonstruovat obraz. Používanými rekonstrukčními algoritmy jsou filtrovaná zpětná projekce či iterativní rekonstrukce. Předností prvního z nich je výpočetně menší náročnost, tedy rekonstrukce je rychlejší. Nicméně algoritmem zpětné projekce se zavádí do obrazu větší míra šumu a artefaktů. Tuto míru dokáže snížit iterativní rekonstrukce, ovšem pro rekonstrukci obrazu o velikosti 512×512 pixelů, který se v CT běžně používá, je tento algoritmus velmi výpočetně náročný [8, s. 357–358]. Díky stále lepším možnostem počítačů se však dostává tento rekonstrukční algoritmus do popředí.

Pro lepší srovnání obrazů při různých akvizicích se v každém pixelu místo lineárního součinitele útlumu μ zobrazuje CT číslo vyjádřené bezrozměrnou Hounsfieldovou jednotkou (HU) dle rov. 2.1.

$$CT_{\text{číslo}}(x, y, z) = 1000 \cdot \frac{\mu(x, y, z) - \mu_{\text{voda}}}{\mu_{\text{voda}}} \quad [HU] \quad (2.1)$$

Z předchozího plyne, že voda je na obraze vyjádřena jako 0 HU. Vzduch je asi -1000 HU, tuk -80 HU, měkké tkáně leží v rozsahu zhruba 30–220 HU a kost či kontrastní látka dosahují 1000 HU a více [8, s. 325]. Současné CT systémy jsou převážně 12-bitové a nabízí rozsah CT čísel od -1024 do 3071 [40].

Pojmem klasické CT bude mít tato práce na mysli modalitu, která nepracuje s více energetickými spektry, jak je tomu u DECT a MECT. Proto je klasické CT označováno rovněž jako single-energy CT². V literatuře (např. [10, 11, 29]) se též toto CT často označuje jako konvenční („conventional“), nicméně tento pojem není v práci pro klasické CT používán, jelikož by se mohl plést s označením jednoho ze skenovacích módů, jak bylo uvedeno výše a na Obr. 2.1.


2.1 Dual-Energy CT

Dual-Energy CT (DECT) je systém, který používá pro akvizici dat dvě různá energetická spektra. To umožňuje rozlišit tkáně, které byly na klasickém CT nerozlišitelné. Příkladem může být rozlišení jódu a kosti. I když tyto dva materiály mají různé Z , hustota kosti a koncentrace jódu může být zrovna taková, že obě tkáně mají při dané energii ve výsledku stejný útlum. Přidáním druhé energie jsme však schopni celý problém vyřešit, jak demonstruje Obr. 2.2.

V praxi většina systémů pracuje s energetickými spektry, které byly vygenerovány rentgenkou při napětí 80 kV a 140 kV. Nižší napětí než 80 kV není voleno, jelikož by se produkovalo poměrně málo fotonů RTG záření a ještě mnoho z nich by bylo v těle pacienta zcela utlumeno. Větší napětí než 140 kV většinou není na DECT systémech dostupné a navíc by způsobovalo horší rozlišení měkkých tkání³ [11]. Přidáním druhé energie se pak otevírají možnosti pro tvorbu různých virtuálních obrazů, které se již dnes v praxi využívají při různých klinických aplikacích.

²Pozor, single-energy a monoenergetický jsou 2 odlišné pojmy. Single-energy znamená, že CT systém vysílá jedno polyenergetické spektrum, monoenergetický CT systém neexistuje. Single-energy a monoenergetické spektrum bylo demonstrováno na Obr. 1.1.

³Pro úplnost tato práce dodává, že existují systémy, které umožňují navolit vyšší napětí až 150 kV. Co se týká nižšího napětí, v některých případech (např. pediatričtí pacienti) se používá 70 kV. Dále některé „dual-source“ systémy používají místo 80 kV hodnotu 90 či 100 kV, jelikož tato konstrukční technologie jim umožňuje účinnější filtraci [11].



Obr. 2.2: Závislost lineárního součinitele útlumu pro dané tkáně na energii záření. Graf byl pro dané energie vygenerován vynásobením hmotnostního součinitele útlumu (hodnoty převzaté z National Institute of Standards) a hustoty daných tkání – jmenovitě kost ($\rho = 1 \text{ g/cm}^3$), jód ($\rho = 1 \text{ g/cm}^3$) a jód ($\rho = 0,1 \text{ g/cm}^3$). Při reálné akvizici by byly známé hodnoty jen při dvou vyznačených energiích. Šipka vpravo ukazuje případ, kdy nejsme schopni kost a jód o dané koncentraci rozlišit. K tomu nám pomůže nasnímat informace při druhé energii, jak ukazuje šipka vlevo [27].

2.1.1 Konstrukce DECT

Zcela základní myšlenkou je nasnímat celý objem dat nejdříve při jednom napětí rentgenky, a pak celý postup opakovat pro druhé napětí, přičemž anodový proud je upraven tak, aby se při obou napětích na obrazu podílel zhruba stejný počet fotonů⁴. Výhodou tohoto přístupu je hardwarová nenáročnost, naopak limitací špatné časové rozlišení. Proto byl postup skenování změněn tak, že se střídají napětí na rentgence už po nasnímání jednoho axiálního skenu. I tak je však časový interval mezi jednotlivými akvizicemi dlouhý, a proto je tato metoda zcela nevhodná pro snímání pohyblivých orgánů jako je srdce nebo pro sledování šíření kontrastní látky v čase [11]. Nicméně i pro snímání statických situací není tato metoda příliš vhodná, jelikož mezi akvizicemi hrozí pohyb pacienta a spektrální data by pro další analýzy nebyla příliš použitelná [27]. I přes tyto nedostatky je tato technologie, označovaná jako *Sequential scanning* či *Slow kV switching*, některými CT systémy (Canon (dříve Toshiba) či GE Healthcare) nabízena [11].

Fast nebo též *Rapid kV switching* je technologie DECT používána systémy od GE Healthcare [11, 13]. Jelikož na rozdíl od jiné technologie, která bude popsána níže, používá pouze jednu rentgenku, označují se též tyto systémy jako *Single-source DECT*. Jak název napovídá, jedná se o rychlé přepínání (méně než 1 ms [27])

⁴Toho se docílí asi trojnásobným navýšením proudu v mA při 80 kV [17, s. 56].

mezi nižším (80 kV) a vyšším (140 kV) napětím. Toto přepínání se děje mezi snímáním po sobě jdoucích projekcí, proto při jednom napětí se nasnímá projekce pod úhlem $\theta_{1,3,5,\dots,2n-1}$ a při druhém napětí při úhlech $\theta_{2,4,6,\dots,2n}$ [17, s. 60]. Pro zachování dostatečného množství informací pro rekonstrukci obou obrazů je oproti klasickému CT potřeba zdvojnásobit počet projekcí, které se budou snímat za jednu rotaci z n na $2n$ [13]. Rychlé přepínání napětí a zároveň proudu by bylo obtížné, jelikož anodový proud je dán teplotou katodového vlákna, kterou nelze měnit v řádech kHz [8, s. 344]. Proto se volí anodový proud konstantní [17, s. 61]. To však s sebou přináší další problém. Pokud by se totiž při obou napětích snímalo tentýž čas, stejný anodový proud by způsobil nevyváženost obrazů, jelikož tok RTG záření produkovaný rentgenkou by byl při 80 kV mnohem menší než při 140 kV. Tento problém se řeší delším (asi 3x) snímáním projekcí při nižším napětí oproti vyššímu [17, s. 61]. Napěťový průběh na rentgence tohoto DECT systému by měl tedy ideálně vypadat jako obdélníkový průběh se střídou 25 %. Nicméně dokonalého obdélníkového tvaru je poměrně těžké dosáhnout, skoková hrana nebývá v realitě tak ostrá a v důsledku rychlého přechodu se objevují výkyvy od požadovaného napětí směrem nahoru či dolů. Tohle všechno způsobuje poměrně velké překrytí energetických spekter, což pak může činit potíže při rozlišení materiálu⁵ [17, s. 62]. Za další nevýhody „rapid kV switching“ technologie můžou být považovány i hardwarová náročnost pro rychlé přepínání [27] a časově delší akvizice celého objemu dat [17, s. 61]. Výhodou této technologie je však dobré časové rozlišení, protože projekce jsou snímány téměř současně. Malé odchylky v projekčním úhlu (a pozici patientského stolu v ose z v případě helikálního skenovacího módu) mezi akvizicemi pro 80 kV a 140 kV lze vyřešit interpolací mezi projekcemi [17, s. 60]. Jelikož máme dva datasey, které na sebe pasují už v projekční rovině, můžeme již v této rovině provádět materiálovou dekompozici a snížit tak „beam-hardening“ efekt v dopočítaných virtuálních monoenergetických obrazech⁶ [27, 11]. Za zmínku rovněž stojí fakt, že systémy s jednou rentgenkou nabízí sbírat data z celého zorného pole (běžně 50 cm) [11][17, s. 60].

Další možností konstrukce je *Dual-source DECT* rozšířená v systémech Siemens [27, 11]. Jedná se o dvě samostatné soustavy rentgenka-detektor, které jsou vůči sobě kolmo [27][17, s. 62] nebo téměř kolmo [11, 15] uložené v gantry. První systém umístěný na „vnějším okruhu“ nabízí sbírat data z celého zorného pole (50 cm),

⁵Nějaké překrytí polyenergetických spekter při napětí 80 a 140 kV je vždy, nicméně při adekvátní separaci zde existuje poměrně široké pásmo (80–140 keV), kde se spektra nepřekrývají, což umožňuje dobrou diferenciaci.

⁶„Beam-hardening“ efekt plyne z vysílání polyenergetického spektra RTG záření rentgenkou, které se pak utvrzuje (střední hodnota energetického spektra roste) z toho důvodu, že fotony s E_1 objektem projdou, zatímco fotony s E_2 už ne. Virtuální monoenergetické obrazy simulují průchod monoenergetického RTG záření, tj. záření s jednou energií. Díky tomu nedochází k jevu utvrzování svazku a „beam-hardening“ efekt se tím redukuje [30].

druhý systém na „vnitřním okruhu“ zorné pole redukuje (27, 33 či 35 cm, záleží na modelu) [27, 11], což může činit potíže při vyšetřování objemnějších pacientů [17, s. 68]. Data jsou při obou napětích získávána současně, pouze jsou vůči sobě o 90° posunuté. To ale zároveň znamená, že tu je určité časové zpoždění (čtvrtina otáčky gantry) mezi projekcí naměřenou při nižším napětím a tou korespondující při vyšším napětí. U helikálního skenování to má navíc za následek to, že data nejsou získávána současně ve stejné pozici na ose z . Tyto nesnáze pak způsobují to, že se upouští od těžce realizovatelného zpracování duálních dat přímo v projekční rovině a provádí se až v obrazové rovině [27, 13, 11], což může vést k horší redukci „beam-hardening“ efektu a snížení přesnosti materiálové dekompozice [11]. Obecně je však „dual-source“ technologie považována za konstrukci s dobrým časovým rozlišením, která umožňuje akvizici pohyblivých orgánů [17, s. 66]. Problematickým jevem konstrukce s dvěma rentgenkami je tzv. „cross-scattering“. Je to situace, kdy foton z rentgenky A (resp. B) interaguje s hmotou a dojde k jeho rozptylu na detektor B místo A (resp. A místo B). Díky tomu dochází ke zkreslení obrazu [11], čemuž se systémy snaží vyvarovat různými mechanismy [17, s. 69]. Jedna z možností je korekce na základě modelu povrchu. Bylo totiž zjištěno, že hlavním zdrojem „cross-scatteringu“ je Comptonův rozptyl na povrchu objektu. Pokud při jednotlivých projekčních úhlech dokážeme charakterizovat povrch měřeného objektu, který se na „cross-scatteringu“ podílí, a z předchozích měření známé míru „cross-scatteringu“ na obdobném povrchu (na modelu tohoto povrchu), můžeme tuto míru rozptýleného záření z obrazu odečíst [17, s. 70]. Druhou možností je pokusit se míru „cross-scatteringu“ měřit přímo pomocí tzv. „scatter“ senzorů. Ty se uloží vedle pole normálních detekčních elementů tak, aby byly mimo svazek RTG záření. Fotony, které na tyto senzory dopadnou, pak tím pádem budou jen ty rozptýlené a jejich míra se odečte z naměřeného signálu [17, s. 69-70]. Nespornou výhodou systémů s dvěma rentgenkami je možnost regulovat anodové napětí i proud zvlášť pro každou rentgenku, přičemž pro napětí 80 kV se volí asi 3x větší anodový proud než pro 140 kV ze stejného důvodu, jaký byl uveden u „slow kV switching“ systémů. Zároveň lze ke každé rentgence přidat zvláštní filtr, což umožňuje efektivněji oddělit obě energetická spektra [27].


Relativně novou konstrukční technologií, kterou rovněž představila firma Siemens, je *TwinBeam DECT* [11]. Tento systém se skládá z jedné soustavy rentgenka-detektor, přičemž dvouenergetického snímání je docíleno filtrováním za pomoci dvou různých materiálů – zlata a cínu. Rozdělení svazku na stranu s nižší a vyšší energií naznačuje Obr. 2.3. Oproti „single-source“ i „dual-source“ DECT systémům je u této metody horší časové rozlišení mezi nízkoenergetickými a vysokoenergetickými projekcemi. Dalším problémem může být nevyvážený tok fotonů při obou energiích. Může dojít i ke „cross-scatteringu“, kdy se foton z jedné strany svazku rozptýlí tak,



Obr. 2.3: TwinBeam DECT filtruje RTG záření za pomoci dvou filtrů uložených vedle sebe („split filter“). Tím dosáhneme rozdělení svazku na stranu s vyšší (červená) a nižší (modrá) energií. Nízkoenergetické spektrum se vytváří průchodem svazku přes 0,05 mm tlustý zlatý filtr, vysokoenergetické spektrum průchodem svazku přes 0,6 mm tlustý cínový filtr [15].

že dopadne na detektory, které měří druhou stranu svazku [11]. Nutno také uvažovat prostřední část svazku, kdy fotony s nižší a vyšší energií budou v těsné blízkosti. Jelikož měříme útlum ve voxelu o konečné velikosti, dostaneme v těchto voxidech informaci o útlumu smíšeného spektra, nikoliv toho o nižší či vyšší energii [11]. Výhodou tohoto systému je zobrazování v celém zorném poli a hardwarová jednoduchost, kdy tato technologie může být k některým klasickým systémům dodatečně přidána [11].

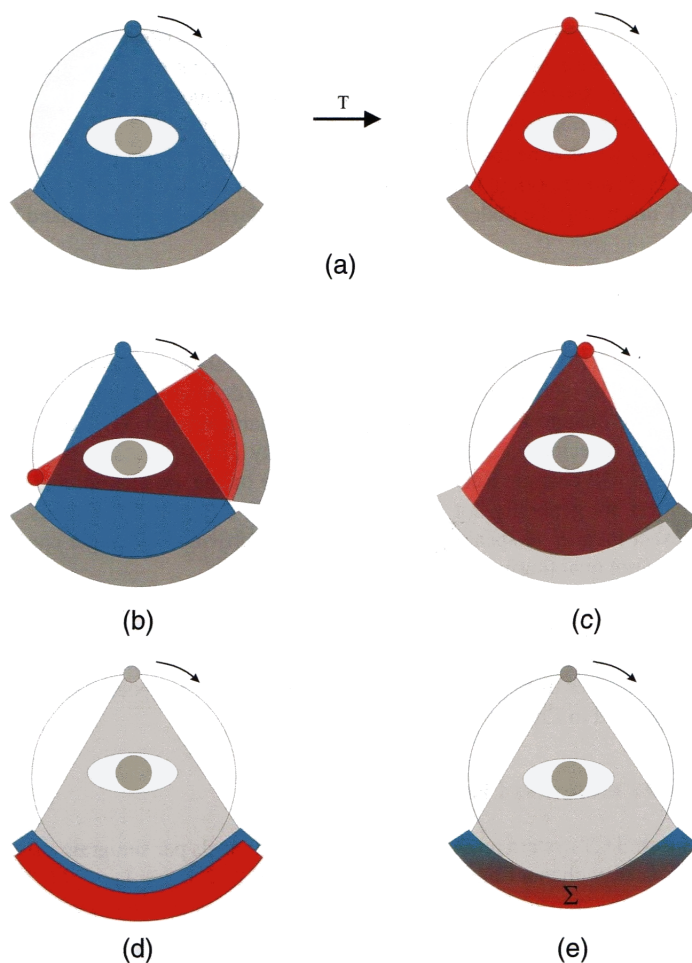
Předchozí konstrukce DECT se snažily o to, aby pacientem prošla dvě různá energetická spektra, jejichž útlum byl dále detekován. Následující metoda používá jedno polyenergetické spektrum, které pak separuje na fotony s nižší a vyšší energií až na úrovni detektorů, jak naznačuje Obr. 2.4. Tento koncept se nazývá jako *Dual-layer detector* a využívá ho firma Philips [11]. Rentgenka je fixně nastavena na 120 kV (běžné napětí u klasického CT) [15]. Detektory sestávají ze dvou různých scintilačních materiálů, přičemž nahoře je uložen ten, který absorbuje nízkoenergetické fotony, a pod ním ten, který absorbuje vysokoenergetické fotony. Díky tomuto vrstevnatému uspořádání se tyto detektory označují též jako sandwichové [27, 11]. Snahou je, aby se celé polyenergetické spektrum rozdělilo zhruba na 50 % fotonů s nižší energií a 50 % s vyšší energií [11]. Vrchní vrstva je tvořena ZnSe [35] či granáty na bázi yttria [15] a je asi 1 mm tlustá. Spodní vrstva je asi 2 mm tlustá a zajišťuje scintilaci ostatních fotonů, které prošly vrchní vrstvou. Volí se GOS (gadolinium oxysulfid) [35, 15]. Jelikož fotony prochází dvěma vrstvami, nejsou u těchto detektorů fotodiody pod scintilátorem, ale na boku. Nevýhodou však je, že senzitivita scintilátorů na danou energii fotonu se překrývá [15, 27], proto např. může být foton s vyšší energií detekován již ve vrchní vrstvě [17, s. 74]. To pak samozřejmě zhoršuje spektrální separaci a materiálovou dekompozici. Výhodou je však skvělé časové rozlišení, jelikož nízkoenergetické a vysokoenergetické projekce pod stejným úhlem jsou získávány současně. Tím se vyvarujeme pohybovým artefaktům mezi energetic-



Obr. 2.4: Dual-layer DECT filtruje RTG záření přímo v detektorech. Nachází se zde dvě scintilační vrstvy o různé tloušťce, které zajišťují rovnoměrné rozdělení fotonů na ty s nižší a vyšší energií. Fotodiody jsou umístěné po stranách a zvrchu chráněny wolframovým štítem, aby na ně nedopadalo jiné záření než ze scintilátorů. Z vrchní vrstvy získáme nízkoenergetická data, ze spodní vrstvy vysokoenergetická. Tato data pak můžeme spojit a vytvořit tak obraz jako z klasického CT [35].

kými projekcemi a máme možnost duálně snímat pohyblivé orgány jako srdce [17, s. 73]. Zároveň projekce na sebe perfektně časově i prostorově sedí, proto lze aplikovat algoritmy zpracování duálních dat přímo v projekční rovině [11, 15]. Zobrazování u „dual-layer“ systémů probíhá v celém zorném poli. Výhodou těchto systémů je rovněž fakt, že nemusíme předem provést rozhodnutí, zda potřebujeme dvou-energetické CT či nikoliv. Spektrální informace lze totiž u této konstrukce kdykoliv dotvořit [11].

Na Obr. 2.5 je grafické zobrazení všech Dual-Energy konstrukcí (kromě TwinBeam konstrukce, která byla demonstrována na Obr. 2.3). Zároveň je na obrázku uveden „photon-counting“ detektor, který detailněji bude vysvětlen u Multi-Energy systémů.



Obr. 2.5: Konstrukce spektrálních systémů [17, s. 20] – slow kV switching (A), dual-source DECT (B), rapid kV switching (C), dual-layer DECT (D) a CT s photon-counting detektorem (E), který bude schopen počítat fotony v jednotlivých energetických pásmech (např. schematicky červené, červenomodré a modré pásmo).

2.1.2 Basis material decomposition (BMD)

Dekompozice materiálu na základní materiály (báze), tzv. „basis material decomposition“ (BMD), je hlavním algoritmem pro zpracování dvouenergetických, potažmo víceenergetických dat [17, s. 25]. Díky tomuto algoritmu lze vytvářet různé virtuální obrazy, které nám mohou dopomoci k diagnostice. Obecně je BMD založeno na faktu, že útlum RTG záření lze vyjádřit jako součet tzv. bazových funkcí $f_i(E)$ („basis functions“) váhovaných konstantami α_i pro $i = 1, 2, \dots, n$, jak naznačuje rov. 2.2 [1]. Přitom $\mu(E)$ máme naměřené, bazové funkce jsou nám známé a dopočítáváme pouze váhové konstanty, které jsou pro daný materiál typické.

$$\mu(E) = \alpha_1 f_1(E) + \alpha_2 f_2(E) + \dots + \alpha_n f_n(E) \quad (2.2)$$

Abychom dokázali najít všechny konstanty α , potřebovali bychom n rovnic, a tudíž nasnímat útlum při n energetických spektrech. U DECT systémů máme informace ze dvou energetických spekter, proto se používá rozložení materiálů na dvě báze, které jsou nazývány jako „material basis pair“ [12]. Lze využít toho, že celkový útlum RTG svazku je dán útlumem v důsledku fotoelektrického jevu a Comptonova rozptylu. Energetické vyjádření obou jevů známe, a proto není problém je použít jako bazové funkce. Vychází nám soustava rov. 2.3 a rov. 2.4, kde α_{ph} (resp. α_{Co}) jsou konstanty pro fotoelektrický jev (resp. Comptonův rozptyl), $\frac{1}{E^3}$ je bazová funkce pro fotoelektrický jev a $f_{KN}(E)$ („Klien-Nishna function“) je bazová funkce pro Comptonův rozptyl [31]. Důležitou poznámkou však je, že zmíněné aproximační funkce neuvážují K-hranu v atenuačním spektru⁷.

$$\mu(E_1) = \alpha_{ph} \frac{1}{E_1^3} + \alpha_{Co} f_{KN}(E_1) \quad (2.3)$$

$$\mu(E_2) = \alpha_{ph} \frac{1}{E_2^3} + \alpha_{Co} f_{KN}(E_2) \quad (2.4)$$

Po vypočtení soustavy rovnic známe konstanty α , díky kterým lze rekonstruovat různé obrazy. Například můžeme simulovat průchod svazku o další energii E_3 , spočítat si hodnotu útlumu a vytvořit tak virtuální monoenergetický obraz⁸. Nebo lze vytvořit obrazy prezentující efektivní atomové číslo (tedy jakési průměrné atomové číslo materiálu skládajícího se z více prvků). Z Tab. 1.1 totiž plyne, že poměr konstant α_{ph} a α_{Co} je úměrný druhé mocnině efektivního atomového čísla (rov. 2.5), z čehož se pak obrazy již snadno mohou odvodit.

$$\frac{\alpha_{ph}}{\alpha_{Co}} \propto (Z^2 = \frac{Z^3}{Z}) \quad (2.5)$$


Za „material basis pair“ nemusí být vždy použita dvojice fotoelektrického jevu a Comptonova rozptylu. Často se používá i vyjádření za pomoci vody a jódu⁹, jak demonstruje Obr. 2.6, kdy $f_1 = \mu_{H_2O}(E)$ a $f_2 = \mu_I(E)$. Koeficienty α budou jiné, nicméně princip je stejný jako výše uvedený. Na základě toho lze pak například

⁷Atenuační spektrum zobrazuje útlumovou charakteristiku daného materiálu. Na ose x je energie rentgenového svazku, na ose y je lineární, popř. hmotnostní součinitel útlumu při dané energii.

⁸Virtuální monoenergetický obraz (VMI) reprezentuje virtuálně útlum svazku o jedné energii [12, 15, 31]. Pojem lze volně zaměnit s označením virtuální monochromatický obraz [15], protože *monochromatický foton* znamená foton o jedné vlnové délce, tudíž i o jedné energii ze vztahu $E = \frac{hc}{\lambda}$.

⁹Jód sice má K-hranu ve svém atenuačním spektru, nicméně na hodnotě 33,2 keV. Běžně dostupné energie pro rekonstrukci virtuálních obrazů jsou 40–200 keV, což je právě z toho důvodu, aby se jód mohl vyjádřit jako kombinace aproximačních funkcí fotoelektrického jevu a Comptonova rozptylu, které s K-hranou nepočítají.

odečíst příspěvek jódu a vytvořit virtuální obraz reprezentující zobrazení bez podání kontrastní látky.



Obr. 2.6: Daný materiál lze vyjádřit libovolně zvoleným „material basis pair“ – zde ukázána možnost rozkladu na fotoelektrický jev a Comptonův rozptyl či na denzitu vody a jódu (přerušované čáry). Důležité je však poznamenat, že koeficienty α neudávají reálnou koncentraci vody a jódu v dané látce, nicméně demonstrují to, že daná tkáň zeslabuje RTG záření stejně jako daná koncentrace vody a jódu [12].

2.1.3 Využití v diagnostice

K systému DECT existuje množství softwarových nástrojů, které umožňují lékařům využít tuto modalitu pro různé klinické aplikace.

Široce využívanou možností je automatické odstranění kostí při CT angiografii [27, 13]. Protože díky DECT dokážeme rozlišit vápník obsažený v kostech a jód v kontrastní látce, lze kost automaticky odstranit a prohlédnout si jen cévní řečiště. To je důležité hlavně v anatomicky komplikovaných oblastech (příkladem může být oddělení lebky a Willisova okruhu [13]).

Jelikož jsme schopni odstranit kost, můžeme zlepšit diagnostiku kostní dřeně. [27, 13]. Pokud je identifikován vápník v kostech, může být počítačově odstraněn a vznikne tzv. „virtual noncalcium image“. Díky tomu může lékař mnohem lépe posoudit stav kostní dřeně, jejíž signál by byl na klasických obrazech skryt díky přítomnosti mnohem většího signálu ze samotné kosti [27].

Virtuální obrazy bez vápníku nemusí sloužit pouze k odstranění kosti, ale například i aterosklerotických plátů [27, 13, 19]. Lze pak jasně označit místa průchodnosti či naopak stenózy v cévním řečišti.

Stejně tak, jak lze odstranit vápník, lze odebrat i jód, čímž vytvoříme tzv. „virtual noncontrast-enhanced images“ [27, 13]. Toho lze využít tam, kde bylo zapotřebí udělat nejdříve nekontrastní snímek a poté kontrastní. Virtuálními obrazy tedy dosáhneme snížení dávky u pacienta. Virtuálních nekontrastních obrazů lze využít například při diagnostice nádorů [12][17, s. 109], případně pro detekci močových kamenů ve vylučovacích cestách [27]. Nicméně je potřeba dávat pozor na to, že virtuální nekontrastní obrazy nedosahují takové kvality jako klasické obrazy bez kontrastu, proto lze na virtuálních malý útvar přehlédnout [27].

Pomocí tzv. „uric acid images“ je možné posoudit typ močového kamene, jelikož pomocí DECT systémů lze určit, zda konkrétně obsahuje kyselinu močovou či ne. To je diagnosticky významné, jelikož pouze urátové kameny lze alkalizací účinně léčit [27, 13].

Dalším nabízeným obrazem je jódová mapa, která zobrazuje koncentraci jódové složky v daném pixelu při rozložení materiálu na vodu a jód, jak bylo popsáno na Obr. 2.6. V místech, kde se jód opravdu vyskytuje, lze koncentraci jódu kvantifikovat a určit tak například míru vychytávání jódu danou tkání, což lze použít při diagnostice nádorů [13].

Pro posouzení typu močového kamene či určení oblasti vychytávající jód lze využít rovněž obrazy zobrazující efektivní atomové číslo. Tyto obrazy jsou zpravidla v barevné škále [31].

Virtuální monoenergetické obrazy (VMI) umožňují simulovat podobu obrazu při průchodu RTG svazku o jedné energii [12, 15, 31]. Tímto způsobem lze dostat obrazy o různém kontrastu tkání, které nám mohou pomoci k rozeznání odlišných struktur. VMI rovněž snižují „beam-hardening“ artefakt v obraze [31].

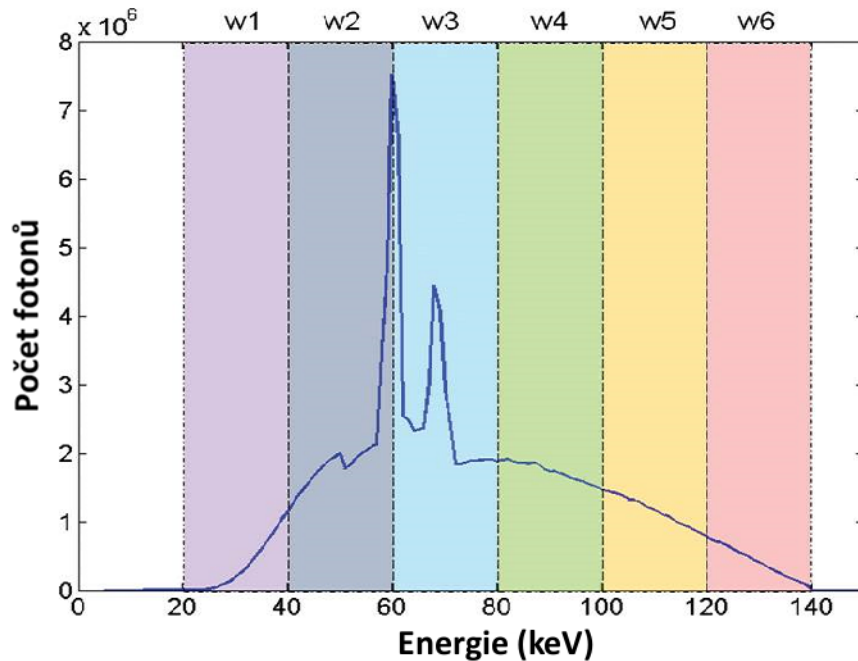
2.2 Multi-Energy CT

Multi-Energy CT (MECT) je systém, který dokáže rozlišit více energetických spekter. V následujících odstavcích bude vysvětlena možná konstrukce a využití MECT.

2.2.1 Konstrukce MECT

MECT skenovací systémy se v současnosti vyvíjí a nejsou komerčně dostupné [27, 11]. Jeden z možných uvažovaných způsobů realizace víceenergetického CT je využívat „dual-source“ technologii, kdy by na jedné z rentgenek či obou byla přidána technologie TwinBeam [11]. Tak bychom mohli získat informace ze tří či čtyř energetických spekter. Více diskutovanější variantou je však tzv. „photon-counting“ detektor [27, 13, 11].

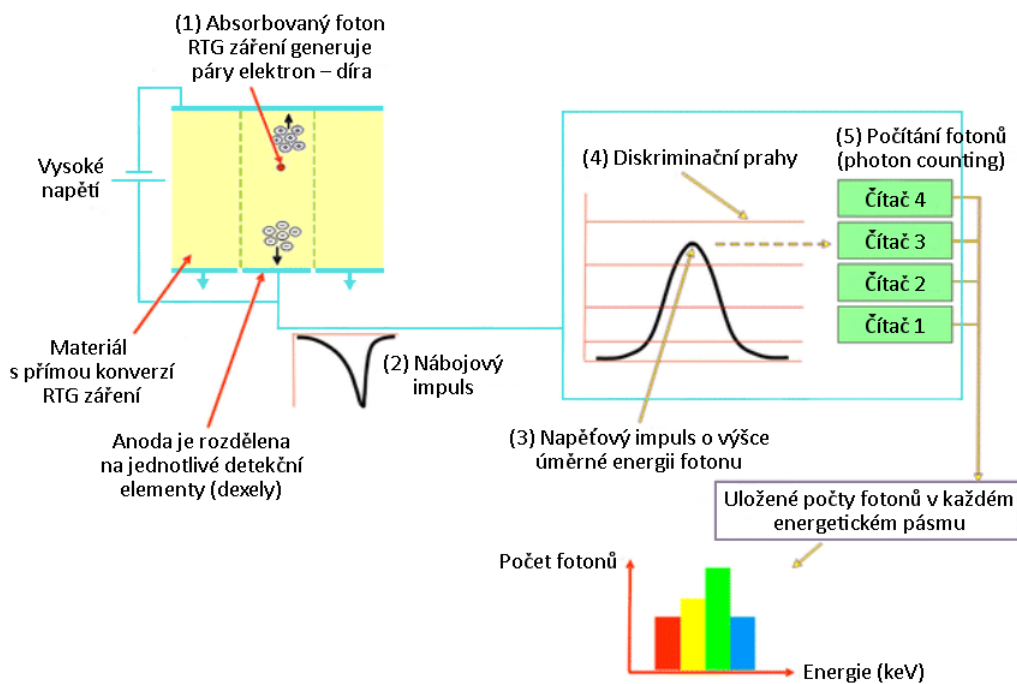
Tento detektor dokáže spočítat jednotlivé fotony RTG záření, které dopadly na detekční plochu, a určit jejich energii. Na základě této energie dokáže jednotlivé RTG fotony rozdělit do energetických pásem (tzv. biny), které byly předem zvoleny udáním jednotlivých prahů [27, 11]. Pokud máme dva biny, jedná se o DECT, pokud více dosáhli jsme MECT. Rozdělení do 6 binů demonstruje obrázek Obr. 2.7.



Obr. 2.7: Rozdělení energetického spektra do 6 energetických pásem (binů) [27]. Photon-counting detektor by měl počítat fotony v každém z pásem. Na základě tohoto by mohlo být zrekonstruováno 6 typů obrazů, které by demonstrovaly, jak by vypadal obraz při průchodu RTG záření o energiích 20–40 keV, 40–60 keV, atd.

Detektory by se zřejmě vyráběly z kadmium telluridu (CdTe) či kadmium zink-telluridu (CZT) [27, 34][17, s. 79]. Po dopadu RTG záření by v tomto polovodiči vznikl náboj ve formě děr a elektronů přímo úměrný energii dopadajícího fotonu [27, 32]. Vnější elektrické pole připojené k polovodiči způsobí dočasný proud těchto elektrických částic k elektrodám a dále k nábojovému zesilovači, který na základě množství uvolněného náboje v polovodiči vyprodukuje příslušný napěťový impuls [35]. Dále tento signál vstupuje do bloku, který rozlišuje výšku impulsu [27]. Na základě nastavených prahů bude výstupem tohoto bloku buď logická 1, pokud foton patří do daného energetického binu, nebo logická 0, pokud nepatří. Závěrečným prvkem je čítač, jehož výstupem je počet logických 1, tedy fotonů v jednotlivých energetických pásmech [27]. Celý princip fungování photon-counting detektoru naznačuje Obr. 2.8.

Ačkoliv se photon-counting detektory již v jiných oblastech medicíny používají (např. v nukleární medicíně), u CT systémů se řeší několik problémů [27, 11]. Předně



Obr. 2.8: Základní schéma fungování photon-counting detektoru [35]. Ve vrstvě polovodiče dojde k přímé konverzi RTG záření na elektrický signál. Nábojovým zesilovačem je vyprodukován napěťový impuls, který odráží celkové množství vyprodukovaného náboje v polovodiči jedním fotonem. Další blok rozlišuje výšku napěťového pulsu porovnáním s danými prahy, přičemž vrací logickou 1, pokud je impuls v daném binu. Posledním krokem je určit počet RTG fotonů v tomto binu za danou jednotku času, což se děje pomocí čítače.

je to mnohokrát větší tok fotonů RTG záření (zhruba 10^9 fotonů/s/mm²), který na detektor dopadá [27]. Díky tomuto nahromadění (tzv. „pulse pile-up effect“) dochází k chybám v počítání fotonů až k úplnému ochromení detektoru [27, 11]. Dalším problémem je možná reemise charakteristického RTG záření („K-escape“) či sdílení náboje více elektrodami („charge sharing effect“), což pak vede k chybám v počtech [27, 11].

Nicméně photon-counting detektory se ukazují jako slibná budoucnost CT zobrazování. Za prvé nám umožní multi-energetické zobrazování. Za druhé by mohly nabídnout obrazy s lepším prostorovým rozlišením [27], jelikož zde není třeba oddělovat jednotlivé detekční prvky, jak je tomu u integrálních scintilačních detektorů, tj. nevzniká tu žádný mrtvý prostor, kterým bychom byli limitováni. Za třetí nabídnou obrazy s lepším kontrastem, jelikož neznevýhodňují svým principem nízkoenergetické fotony RTG záření, které hrají významnou roli v kontrastním rozlišení tkání. Dnes používané integrální detektory nejsou schopny rozlišit jednotlivé fotony, a proto po nasnímaní jedné projekce bude na výstupu detektoru signál S_{int} daný rov. 2.6, kde E je energie daného fotonu a $\Phi(E)$ je tok RTG záření, tedy počet fotonů o dané energii, které za daný čas dopadly na detektor.

$$S_{int} = \int_0^{\infty} E \cdot \Phi(E) dE \quad (2.6)$$

Ze vztahu je patrné, že fotony jsou váhované dle své energie, tedy zde dochází k již zmiňovanému podhodnocování váhy nízkoenergetických fotonů. Photon-counting detektor však jednoduše přičte 1, pokud je energie fotonu větší než zvolený práh E_1 . Výstupní signál detektoru S_{count} tedy všem energiím fotonu přisuzuje stejnou váhu a předchozí vztah lze přepsat jako rov. 2.7 [17, s. 78-79].

$$S_{count} = \int_{E_1}^{\infty} 1 \cdot \Phi(E) dE \quad (2.7)$$

Čtvrtým přínosem photon-counting detektorů bude zmenšení šumu v obrazech, což umožní snížit dávku pacienta [27]. Čím nižší dávka, tím více se kromě užitečného signálu projevuje elektronický šum. Zvolením vhodného prahu můžeme docílit toho, že eliminujeme signál, který by byl pouze ze samotného šumu, což vede ke zlepšení kvality obrazu [27, 11].

2.2.2 Využití v diagnostice

Jelikož Multi-Energy CT je rozšířením DECT, lze předpokládat, že by šlo MECT využít na diagnostické problémy uvedené v kapitole 2.1.3. Další využití víceenergetického CT je předmětem výzkumu ve vědeckých laboratořích [13].

Prvním uvažovaným využitím je detailnější charakterizace tkání [13]. Pokud máme spektrální informace z N energetických binů, danou tkáň popisuje N parametrů namísto dvou, jak je tomu u DECT. Díky tomu lze provádět různé víceparametrické analýzy, které nám mohou pomoci tkáň lépe rozlišit. To by se mohlo uplatnit například při klasifikaci různých typů nádorů.


Další velkou kapitolou je K-zobrazování („K-imaging“), tj. rozlišení prvků na základě jejich K-hran („K-edges“) v atenuačním spektru [13, 12]. K-hrana je náhlý vzrůst útlumu procházejícího záření v důsledku překročení vazebné energie elektronů K vrstvy a zvýšení útlumu v důsledku fotoelektrického jevu. Tento skok se u energií běžně používaných k zobrazování objevuje u prvků s relativně velkými atomovými čísly [16, 2] a je charakteristický pro daný prvek. Díky typickému tvaru K-hrany musí být v rovnici BMD zahrnuta kromě fotoelektrické složky a Comptonova rozptylu i složka reprezentující útlum pro daný prvek s K-hranou (rov. 2.8) [17, s. 82].

$$\mu(E) = \alpha_{ph} \frac{1}{E^3} + \alpha_{Co} f_{KN}(E) + \alpha_{K-edge} f_{K-edge}(E) \quad (2.8)$$

Pokud bychom chtěli například rozlišit měkké tkáně, kost, jód a gadolinium, rovnice bude vypadat následovně:

$$\mu(E) = \alpha_{ph} \frac{1}{E^3} + \alpha_{Co} f_{KN}(E) + \alpha_{I} f_I(E) + \alpha_{Gd} f_{Gd}(E) \quad (2.9)$$

Přítom kombinace fotoelektrického jevu a Comptonova rozptylu rozliší měkkou tkáň od kosti a další dvě funkce plně vyjadřují útlum jódu a gadolinia včetně jejich K-hrany [34]. K rozlišení K-hran je tedy potřeba více binů, přitom informace o útlumu musí být naměřeny z obou stran K-hrany [2]. Díky Multi-Energy CT lze tedy tyto K-hrany najít a vzájemně je odlišit, čímž bychom dokázali rozlišit více kontrastních látek, jak demonstruje Obr. 2.9. Jód, který se dnes běžně jako kontrastní látka používá, však z hlediska K-zobrazování není zrovna vhodným kandidátem. Jeho K-hrana (33,2 keV) totiž leží za hranicí běžně používaných energií při zobrazování člověka. Většina fotonů s takhle nízkou energií je buď za rentgenkou odfiltrována, nebo se pohltí v pacientovi a nepodílí se na obrazové informaci [17, s. 100]. Z tohoto hlediska jsou mnohem diskutovanější gadolinium (K-hrana na energii 50,2 keV), zlato (80,7 keV), popřípadě bismut (90,5 keV). K-zobrazování tedy otevírá brány k výzkumu jednotlivých kontrastních látek a jejich možných aplikací v medicíně [34]. Mnoho skupin cílí na nanočástice označené zlatem, jehož K-hrana by se detekovala. Tyto nanočástice by se mohly vázat na specifická místa, což by umožňovalo funkční zobrazování [13].



Obr. 2.9: Ukázka rozlišení kosti, jodové kontrastní látky a baryové kontrastní látky u myši. Na klasickém CT nejsme schopni tyto materiály rozlišit (a). Pomocí MECT rozlišíme kost, jód přítomný v krevním řečišti (červeně) a baryum přítomné v plicích (žlutě). (b) Vzdálenost K-hran je přitom asi 4 keV [13]. Nutno dodat, že K-hrany na tak nízkých energiích se dobře hledají u méně objemné scény jako je myš. U člověka by to bylo díky většímu útlumu problematictější.

3 Přehled segmentačních metod

Při analýze obrazu se zásadním způsobem uplatňuje segmentace. Jejím cílem je obraz rozdělit na části (objekty), které mají přímou souvislost s reálnými objekty, které jsou na obraze zobrazeny [36, s. 175]. K segmentaci existují tři základní přístupy. Při ruční segmentaci rozhoduje o zařazení pixelů do objektu pouze člověk, tím že vybírá přesně oblast objektu. Výhodou je jednoduchost, mezi nevýhody však patří velká časová náročnost a malá reprodukovatelnost. Na tyto nevýhody reaguje automatická segmentace, která je plně v roli počítače. Nicméně plná automatizace může způsobovat chyby na odlišných obrazech (např. v kontrastu, šumu, atd.), na kterých byly automatické segmentační metody natrénovány. Kompromisem mezi těmito dvěma přístupy je poloautomatická segmentace, při níž spolupracují člověk i počítač. Máme tak možnost dodatečně upravovat výsledek automatické segmentace a nastavovat vhodné parametry segmentačních metod¹, které mohou vést k lepší automatické segmentaci objektů [4, s. 40–41]. Poloautomatická segmentace tedy nabízí využití znalosti člověka o datech a zároveň rychlosti počítače.

Segmentačních metod je velké množství. Tato kapitola si však klade za cíl představit pouze ty, které budou diskutovány dále v této práci. Konkrétně jsou to ty nabízené v MATLAB aplikaci *Image Segmenter*, která byla vybrána jako vhodné prostředí pro segmentaci.

3.1 Prahování

Prahování je základní segmentační metodou, která rozděluje obraz pomocí jednoho či více prahů. Ty mohou být pro celý obraz stejné nebo mohou být funkcí prostorové souřadnice v obrazu (tzv. adaptivní prahování) [36, s. 176–177].

Pokud uvažujeme pouze jeden práh, jedná se o prosté prahování, které lze zapsat dle rov. 3.1, přičemž $f(x, y)$ je hodnota parametru obrazu na pixelu daném souřadnicemi x a y , P je práh a $g(x, y)$ je binární obraz, který dělí obraz na objekt a pozadí (tzv. maska).

$$g(x, y) = \begin{cases} 1, & f(x, y) \geq P \\ 0, & x < P \end{cases} \quad (3.1)$$

3.2 Narůstání oblastí

Tato segmentační metoda je založena na hledání regionu pixelů s podobnými vlastnostmi, které by měly tvořit objekt. Na začátku se definuje tzv. semínko, což je

¹Za parametry segmentačních metod lze považovat například hodnotu prahu, polohu semínka, počáteční tvar a umístění kontury, atd.

jeden pixel, který do objektu určitě patří. Dále se rozhoduje o zařazení okolních pixelů do objektu, přičemž běžně uvažujeme buď čtyřokolí nebo osmiokolí [5, s. 181]. Způsobů, jak rozhodnout o zařazení okolních pixelů do objektu je více, mezi základní patří tento: Pokud má pixel v okolí hodnotu parametru v rozmezí $S \pm tol$, kde S je hodnota parametru semínka a tol je zvolená tolerance, je tento pixel přidán do oblasti objektu. V opačném případě bude zařazen do pozadí a nebude se s ním již dále pracovat.

Zatímco v prvním cyklu je výchozím bodem pro hledání okolí semínko, v dalších cyklech jsou těmito body již přidáné pixely, které byly zařazeny do objektu v předcházejících cyklech. Dochází tak k narůstání oblasti objektu do té doby, dokud existují v sousedství podobné pixely.

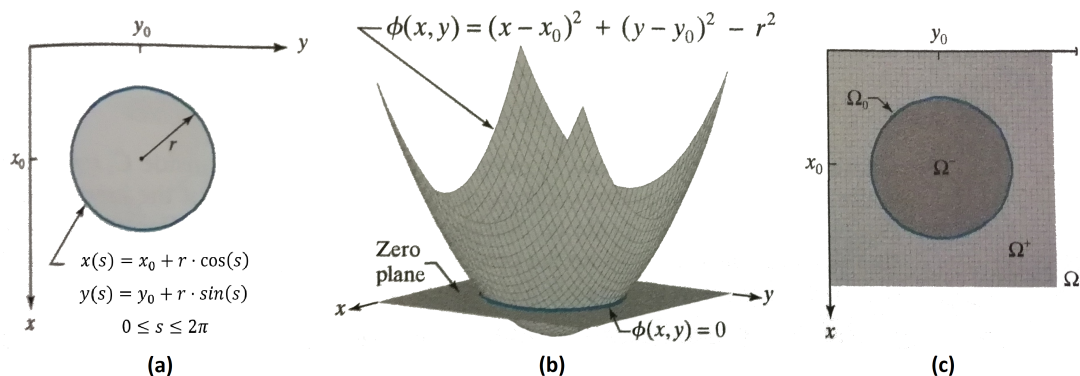
3.3 Aktivní kontury

Aktivní kontury se snaží objekt vyjádřit pomocí deformovatelných modelů, které se snaží minimalizovat svoji energii. Ta je dána sumou energie vnější a vnitřní, proto mezi těmito energiemi musíme najít kompromis. Vnitřní energie se snaží zabránit tomu, aby model byl nepřirozeně krouživý, jelikož reálné objekty tak většinou nevypadají. Na vnější energii se podílí samotný obraz, který působí na model tak, aby se pohyboval do oblasti zájmu (např. směrem k hranám). Jelikož se tyto modely za účelem dosažení minimální energie dynamicky mění, říkáme jim aktivní [14, s. 878–881].

Jsou dva přístupy jak konturu vyjádřit a to buď explicitně prostřednictvím parametrických rovnic, nebo implicitně pomocí funkce o dvou proměnných („level set“ funkce $\Phi(x, y)$), kterou když protneme rovinou, dostaneme konturu² [14, s. 878]. První přístup se často označuje jako „snakes“, druhý jako „level set“ a zobrazuje je obrázek Obr. 3.1. Rovina, která „level set“ funkci protíná je zpravidla definovaná jako nulová vrstevnice, tj. pro $\Phi(x, y) = 0$. Pokud množinu (neboli set) všech bodů na obraze označíme jako Ω , pak průnikem nulové vrstevnice s funkcí získáme množinu bodů Ω_0 patřících do kontury ohraničující objekt. Množina bodů, pro něž platí $\Phi(x, y) < 0$, se označuje jako Ω^- , naopak množina bodů, pro něž platí $\Phi(x, y) > 0$, se označuje jako Ω^+ . Ω^- a Ω^+ vyjadřují oblast objektu a pozadí [14, s. 903].

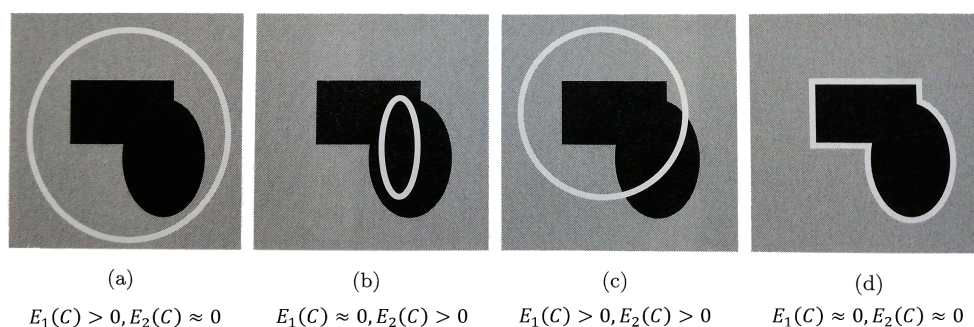
Aktivní kontury v aplikaci *Image Segmenter* využívají k rozvíjení modelu přístup „level set“ [25]. Kromě inicializační kontury lze dále v aplikaci nastavit, zda chceme jakousi sílu, která ovlivňuje rozvoj modelu (tzv. „speed function“ [14, s. 906–927]), založit na hranách v obraze („edge-based“), či na vlastnostech určité oblasti („region-based“). Metoda založená na hranách rozhoduje o rozvoji modelu na základě gra-

²Uvažuji segmentaci 2D obrazu.



Obr. 3.1: Ukázka explicitního a implicitního vyjádření kružnice [14, s. 903]. Explicitní vyjádření je určeno parametrickými rovnicemi s parametrem s (a), zatímco implicitní je určeno „level set“ funkcí $\Phi(x, y)$ (b). Výsledná kontura se získá průnikem roviny s touto funkcí, přičemž rovina se běžně volí na nulovém levelu, tzn. pro $\Phi(x, y) = 0$. Obrázek (c) ukazuje rozdělení obrazu na množiny tak, jak bylo definováno v textu. Není však pravidlem, že objekt je vždy definován jako Ω^- a pozadí jako Ω^+ , záleží na implementaci [14, s. 930].

dientu v obraze. Pokud se dosáhne místa s vysokým gradientem, model se již dále nemění, jelikož zřejmě byly nalezeny hrany objektu [14, s. 923][36, s. 277]. Metoda označovaná jako Chan-Vese neuvažuje gradient, nýbrž podobnost v jednotlivých regionech. Energie je dána rozptylem uvnitř kontury a vně, jak naznačuje Obr. 3.2. Aby bylo umožněno řešit komplikovanější problémy než je na Obr. 3.2, byly do rovnice energie přidány rovněž členy regulující délku a plochu uvnitř kontury [36, s. 281][14, s. 929].



Obr. 3.2: Přístup Chan-Vese algoritmu k minimalizaci energie modelu kontury [36, s. 281]. E_1 udává energii uvnitř kontury, zatímco E_2 vně. Celková energie modelu, kterou se snažíme minimalizovat, je dána součtem obou energií. V tomto případě bude (D) vyhodnoceno jako nejvhodnější řešení segmentace, jelikož rozptyl uvnitř a vně kontury je nejmenší možný.

3.4 Morfologické operace

Tyto metody se spíše než samotnou segmentací zabývají úpravou tvaru masky (tedy binárního obrazu obsahujícího 1 v místě objektu a 0 v místě pozadí), která mohla být získána některou z předcházejících metod. To provádí pomocí tzv. strukturního elementu, který se pohybuje po obraze a na každém pixelu se vyhodnocuje výsledek dané morfologické operace, který se ukládá do výstupního binárního obrazu. Na obraz i strukturní element se přitom nahlíží jako na množinu pixelů, morfologické operace jsou tak dány množinovými operacemi [38, s. 110–111].

Dilatace je operací, která zkoumá průnik strukturního elementu a části obrazu, na které je strukturní element „položen“. Pokud výsledkem tohoto průniku není prázdná množina (tj. pod aspoň jednou jedničkou strukturního elementu se nachází jednička ve vstupním binárním obraze), je příslušnému pixelu ve výstupním obraze přiřazena hodnota 1, v opačném případě 0 [38, s. 113]. V praxi to znamená vyplnění menších děr (oblast nul uzavřených okolo jedniček) ve vstupní masce a rozšíření oblasti objektu, jelikož pixely pozadí sousedící s objektem budou dilatací změněny na objekt [4, s. 115].

Eroze zkoumá, zda je strukturní element podmnožinou dané části obrazu (tj. zda pod všemi jedničkami strukturního elementu jsou jedničky i v binárním vstupním obraze) [38, s. 111]. Pokud ano, příslušný pixel ve výstupním obraze bude mít hodnotu 1, pokud ne, přísluší mu 0. Eroze má opačný efekt než dilatace – díry v masce rozšiřuje a objekt celkově zmenšuje, jelikož okrajové pixely objektu jsou po erozi zařazeny do pozadí. Erozi se dají účinně odstranit izolované pixely či souvislé, ale velmi úzké oblasti [4, s. 115].

Je důležité si uvědomit, že dilatace a eroze nejsou inverzní transformace [36, s. 665], tj. pokud je obraz např. dilatován a pak je tento dilatovaný obraz erodován, nemusíme dostat původní obraz (dilatace může vyplnit menší díry, které eroze pak neodhalí). Proto lze zavést operaci otevření, která sestává nejdříve z eroze a poté dilatace, a operaci uzavření, která je kombinací dilatace a následné eroze. Výhodou těchto přístupů je, že rozměry objektu zůstanou zachovány, zatímco se provedou požadované úpravy – u otevření odstranění izolovaných pixelů či úzkých oblastí objektu, u uzavření výplň děr [4, s. 116].

4 Statistika a klasifikace

4.1 Velikost účinku

P-hodnota ve statistice určuje, zda mezi skupinami je, či není statistický rozdíl. Při velkém počtu dat však i nepatrná změna ve skupinách může způsobit, že p-hodnota bude významná [37]. Praktická využitelnost tohoto rozdílu mezi skupinami však může být nulová. Velikost účinku („effect size“) přímo stanovuje míru rozdílnosti mezi skupinami [37], jinak řečeno popisuje praktickou významnost rozdílu mezi skupinami. Metrik velikosti účinku je několik, tato práce využívala Cohenovo d pro data s normálním rozložením a Cliffovo delta pro data s nenormálním rozložením.

Cohenovo d je dáno rov. 4.1, kde x_1 (resp. x_2) je průměrná hodnota první (resp. druhé) skupiny a σ je sdružená směrodatná odchylka¹ [37].

$$d = \frac{|\bar{x}_1 - \bar{x}_2|}{\sigma} \quad (4.1)$$

Cliffovo delta je neparametrickou variantou velikosti účinku. Je dáno rov. 4.2, kde x_1 (resp. x_2) jsou hodnoty první (resp. druhé) skupiny a n_1 (resp. n_2) značí velikost vzorku první (resp. druhé) skupiny. Každá hodnota ze skupiny jedna je srovnána s každou hodnotou ze skupiny dva, $\#$ značí počet [24].

$$delta = \frac{|\#(x_1 > x_2) - \#(x_1 < x_2)|}{n_1 \cdot n_2} \quad (4.2)$$

Z obou rovnic uvedených metrik lze vynechat absolutní hodnotu a zjistit tak, která ze skupin nabývá vyšších hodnot. Velikosti účinku na základě jednotlivých metrik shrnuje Tab. 4.1.

Cohenovo d	Cliffovo delta	Kolik procent se nepřekrývá	Označení efektu
0	0	0	
0,2	0,15	15	malý
0,5	0,33	33	střední
0,8	0,47	47	velký
1,0	0,55	55	
2,0	0,81	81	

Tab. 4.1: Velikosti účinku a jejich důsledky. Cohenovo d vyjadřuje vzdálenost průměrů dvou skupin při jednotkové směrodatné odchylce. Cliffovo delta vyjadřuje míru překrytí rozložení obou skupin. Čím vyšší velikost účinku, tím větší rozdíl mezi skupinami.

¹Sdružená směrodatná odchylka se vypočítá dle vztahu $\sigma = \sqrt{\frac{(n_1-1) \cdot \sigma_1^2 + (n_2-1) \cdot \sigma_2^2}{n_1+n_2-2}}$, kde σ_1 (resp. σ_2) je výběrová směrodatná odchylka první (resp. druhé) tkáně a n_1 (resp. n_2) je velikost vzorku první (resp. druhé) skupiny.

4.2 ROC křivka

ROC křivka (z anglického „receiver operating characteristic curve“), je nástroj, pomocí něhož lze zhodnotit úspěšnost klasifikace na základě zvoleného parametru. X-ovou osu ROC křivky tvoří $(1 - \text{specificita})$, y-ovou osu senzitivita při zvoleném prahu. K vysvětlení senzitivity a specificity je zapotřebí vyznat se v pojmech pravdivě negativní (TN), falešně negativní (FN), pravdivě pozitivní (TP) a falešně pozitivní (FP)², které demonstruje Tab. 4.2.

	skupina 1	skupina 2
skupina 1 na základě parametru	TN	FN
skupina 2 na základě parametru	FP	TP

Tab. 4.2: Matice záměn („confusion matrix“)

Senzitivita je pak dána rov. 4.3, specificita jako rov. 4.4.

$$Se = \frac{TP}{TP+FN} \quad (4.3)$$

$$Sp = \frac{TN}{TN+FP} \quad (4.4)$$

Zásadním parametrem u ROC křivky je plocha pod křivkou (AUC), která určuje kvalitu klasifikace na základě daného parametru. Jelikož je ROC křivka vykreslena v jednotkovém čtverci, maximální možná plocha odpovídá 1. Při $AUC = 1$ jsou skupiny na základě zvoleného parametru stoprocentně rozlišitelné. Pokud je AUC menší než 0,5, je navržený klasifikátor horší než náhodná klasifikace [8, s. 98].

4.3 Náhodný les

Náhodný les („Random Forest“) je metoda strojového učení s učitelem založená na několika rozhodovacích stromech. Každý strom určí (nezávisle na ostatních stromech) třídu, do které daný testovací vektor patří. Dle algoritmu náhodného lesa pak bude testovací vektor zařazen do té třídy, pro kterou se rozhodla většina stromů [33].

Trénovací data pro každý strom jsou vytvořena náhodným výběrem dat z celého datasetu, přičemž daný trénovací vektor může být vybrán i vícekrát (tzv. „bootstrapping“) [6, s. 23]. Dále je vybráno náhodně několik příznaků (běžně odmocnina z celkového počtu příznaků [3]), ze kterých je vybrán ten příznak, který třídy nejlépe odlišuje. Tento příznak bude tvořit kořen, resp. uzel daného stromu. V růstu stromu se pokračuje, dokud uzel nereprezentuje pouze jednu skupinu [39] (tzv. terminální uzel neboli list). Výsledná predikce třídy náhodného lesa spočívá

²Zkratky TN, FN, TP a FP pocházejí z anglických výrazů „true negative“, „false negative“, „true positive“ a „false positive“.

v agregaci predikcí jednotlivých stromů. Tento přístup se označuje jako „bootstrap aggregation“ nebo zkráceně „bagging“ [3, 33][6, s. 656].

„Bootstrappingem“ dochází k tomu, že některá data mohou být k trénování klasifikátoru použita vícekrát a jiná ani jednou. Udává se, že na trénování daného stromu se využijí pouze zhruba dvě třetiny původního datasetu [33]. Zbývá jedna třetina, označována jako „out of bag“ se využívá k testování na daném stromu. Odhad chyby celého náhodného lesa (tzv. „out of bag error“ [3]) je proveden následovně:

- 1) Je vybrán jeden vektor příznaků z původního datasetu.
- 2) Jsou nalezeny všechny stromy, které nebyly na vektoru z bodu 1 trénovány (asi jedna třetina celkového počtu stromů tvořících les [33]).
- 3) Vektor z bodu 1 se otestuje pomocí náhodného lesa tvořeného stromy z bodu 2.
- 4) Body 1–3 se opakují do té doby, dokud nebyly otestovány všechny vektory příznaků. Poté se přechází na bod 5.
- 5) Odhad chyby náhodného lesa je dán poměrem špatně klasifikovaných vektorů ku všem testovaným vektorům [33].

Na základě analýzy této chyby se vzrůstajícím počtem stromů lze určit vhodný počet stromů pro náhodný les.

Náhodný les má díky různě vzrostlým stromům dobrou generalizační schopnost, neklade zvláštní požadavky na rozložení dat [33], učení i vybavování je poměrně rychlé a je uživatelsky přívětivé, jelikož se nastavuje malé množství parametrů metody [3]. I proto je nyní „Random Forest“ jednou z nejrozšířenějších metod strojového učení [33, 3, 39].

5 Dostupná data a metodika

5.1 Dostupná data

K dispozici byla data 14 pacientů nasnímaná zařízením *IQon Spectral CT* od firmy Philips. Jedná se o „dual-layer“ DECT, které nabízí rekonstruktor pro tvorbu VMI, ale i dalších parametrických obrazů. Samotná data pocházela většinou ze skenování lumbální oblasti, pouze jednomu pacientovi byl proveden hrudní sken. Zorné pole bylo zaměřeno zejména na oblast páteře, od čehož se odvíjela dostupnost tkání k segmentaci. Všechny obrazy se nacházely ve formátu DICOM¹ a měly rozměr 512 x 512 pixelů.

5.2 Rekonstrukce parametrických obrazů

Obraz je dán maticí hodnot parametru, kterým může být například u běžných CT snímků Hounsfieldova jednotka (HU). Tmavé pixely reprezentují nízkou hodnotu HU, naopak jako světlé pixely zobrazujeme ty s vysokou hodnotou HU. Data z *IQon Spectral CT* lze rekonstruovat na nejrůznější typy parametrických obrazů, které lze rozdělit na dvě základní skupiny:


- parametrem obrazu je HU,
- parametrem obrazu je něco jiného než HU.

Do první skupiny kromě klasických CT (kCT) obrazů, které vzniknou vhodným spojením obrazů ze dvou vrstev „dual layer“ detektoru, patří i různé virtuální obrazy. Mezi ně patří například monoenergetické obrazy, obrazy simulující obraz bez podání kontrastní látky, obrazy rozlišující kyselinu močovou či obrazy potlačující vápník. Druhou skupinu tvoří obrazy zobrazující efektivní atomové číslo (parametrem je efektivní Z), nebo jódomové mapy (parametrem je koncentrace jódu v mg/ml) [21]. Obrazy z obou skupin byly představeny v podkap. 2.1.2 a podkap. 2.1.3.

Pro účely této práce byly zrekonstruovány virtuální monoenergetické obrazy (VMI). Rekonstruktor nabízí vytvořit monoenergetické obrazy v rozsahu 40–200 keV s krokem 1 keV. Po zvážení časové náročnosti exportu obrazů u všech pacientů i množství dat, které bude dále zpracováváno, bylo rozhodnuto vytvořit obrazy s jen několika reprezentativními energiemi, konkrétně 40, 50, 55, 60, 65, 70, 80, 90, 100, 120, 140 a 160 keV. Největší změna v podobě obrazů byla subjektivně zaznamenána v rozsahu energií 50–70 keV, proto se zde postupovalo s jemnějším krokem, naopak obrazy nad 100 keV vypadaly podobně, a proto zde bylo postupováno s menším

¹DICOM (z anglického „Digital Imaging and Communications in Medicine“) je běžně užívaný standard pro ukládání a přenos medicínských dat [8, s. 147].

krokem. Jako reference byly pomocí rekonstruktoru vytvořeny i obrazy analogické těm z klasického CT dále označovány jako kCT. Prostředí rekonstruktoru zobrazuje Obr. 5.1.



Obr. 5.1: Vytváření VMI pomocí rekonstruktoru. V levém horním rohu obrazu lze nastavit typ požadovaného parametrického obrazu (v našem případě monoenergetický, tj. *MonoE*), posuvníkem v dolní části si lze vybrat požadovanou energii v keV.


5.3 Metodika charakterizace tkání

Pro charakterizaci jednotlivých tkání bylo potřeba je nejdříve vybrat z rekonstruovaných obrazů segmentačními technikami. Po fázi segmentace a uložení dat pak lze již jednotlivé tkáně charakterizovat.

Základní charakterizace spočívala v popisné statistice, tj. byl sledován tvar rozložení dat a míry polohy i variability u jednotlivých energií VMI. Dalším krokem bylo porovnání charakteristik vybraných dvojic tkání u daného pacienta a určení VMI s nejlepším kontrastním rozlišením těchto tkání. Srovnávat tkáně mezi pacienty není vhodné, jelikož každý pacient může být jiné tělesné konstituce, tj. útlum rentgenového záření u každého pacienta může být o trochu jiný. S využitím dat od více pacientů je však možné prokázat případné zjištěné skutečnosti, které by pouze u jednoho pacienta mohly být považovány za náhodu.

6 Segmentace a sběr dat

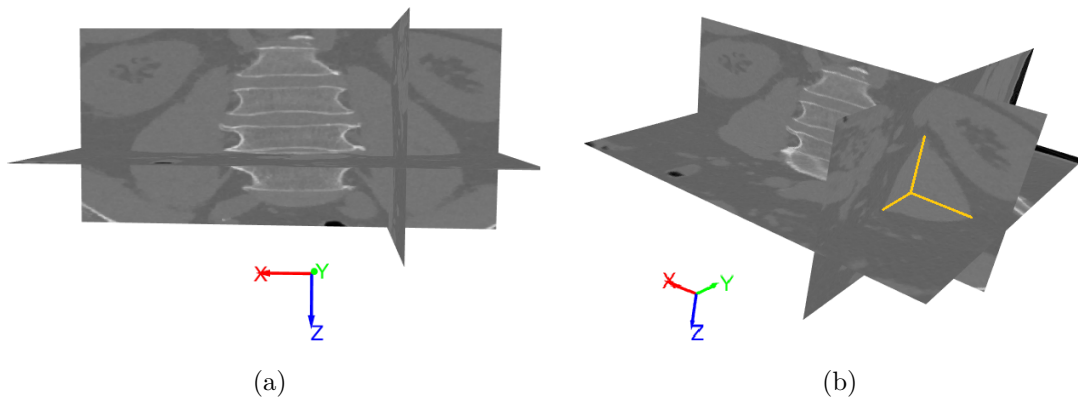
Pro lepší kontrolovatelnost segmentace probíhala ve 2D řezech, které byly vybrány z celého objemu dat pacienta. Byl kladen důraz na to, aby vybrané pixely představovaly opravdu danou tkáň, sporné pixely (např. na hranici dvou tkání) za tkáň raději nebyly považovány. Pro co největší reprezentativnost tkáně byla nasbírána data alespoň z jednoho axiálního, sagitálního a frontálního řezu. Nicméně tímto přístupem byl získán u různě velkých tkání různý počet dat, což není žádoucí z důvodu požadavku nezávislosti klasifikace na velikosti tkání (poměr velikostí tkání se může s číslem řezu měnit – Obr. 6.1). Tato práce si tedy kladla za cíl u všech tkání nasbírat přesně 25 000 pixelů – tento počet byl zvolen jako zlatý střed, jelikož příliš vysoký počet učiní segmentaci malých tkání zbytečně zdlouhavou či dokonce nemožnou (tkáň je natolik malá, že tolik hodnot u ní nelze nasbírat), naopak příliš nízký počet podává malou informaci o větších tkáních. Podrobněji je segmentace i sběr dat popsán v následujících podkapitolách.



Obr. 6.1: Na obrázcích (a, b) jsou vyznačena játra (žlutě) a ledvina (zeleně) u stejného pacienta v různých axiálních snímcích. Poměr velikostí tkání se s různým číslem řezu mění.

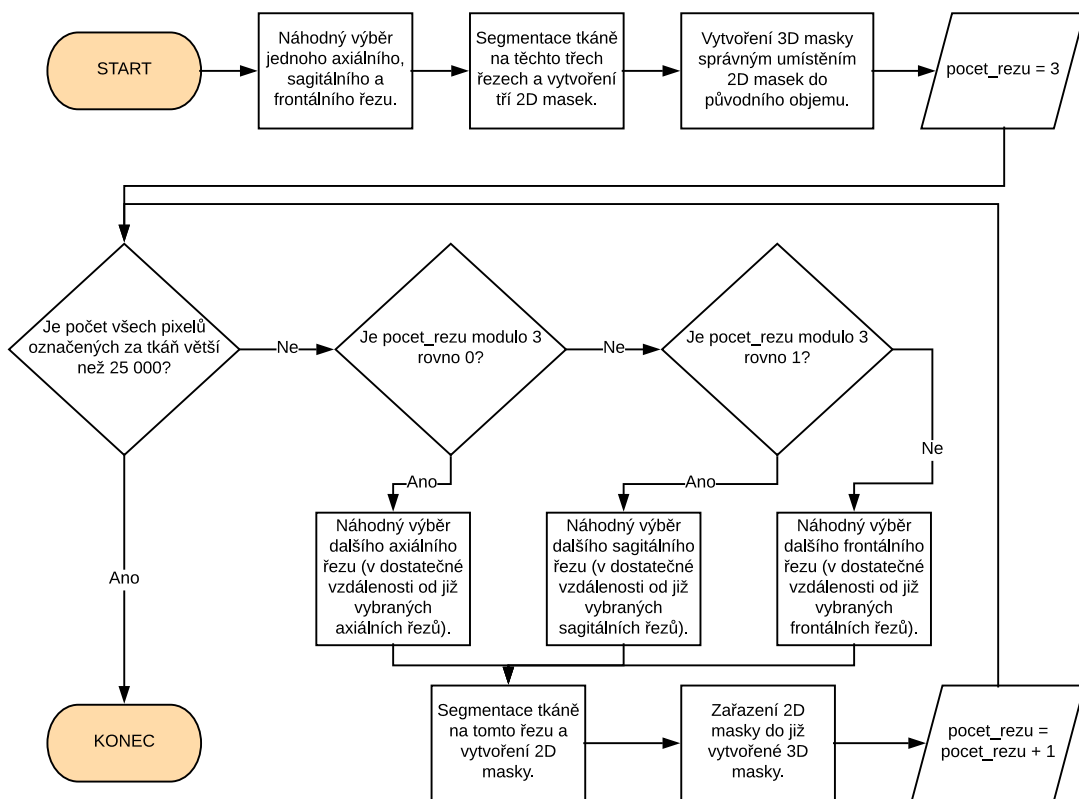
6.1 Segmentace tkání

Segmentace tkání probíhala ve 2D řezech, přičemž jejím výsledkem byla 2D maska, která nabývala 1 tam, kde se nacházela tkáň, a 0 všude jinde. Vynásobením této masky s vybraným 2D řezem lze dostat požadovaná data. Nutno však mít na paměti, že řezy se překrývají, a proto by část nasbíraných dat mohla být započítána dvakrát, jak naznačuje Obr. 6.2. Z tohoto důvodu bylo potřeba nejdříve 2D masky správně poskládat do 3D masky, kde opět hodnota 1 značila tkáň a 0 pozadí. Pokud vynásobíme tuto 3D masku s objemem dat pacienta a vybereme nenulové hodnoty, získáme náhodná, reprezentativní a nezávislá data.



Obr. 6.2: Obrázky (a, b) ukazují průnik jednoho axiálního (dán rovinou XY), sagitálního (dán rovinou YZ) a frontálního (dán rovinou XZ) řezu, přičemž (b) je totožný s (a), pouze jinak natočený. Na tomto příkladu se jedná o sběr dat z velkého bederního svalu, jak naznačuje (a). Na obrázku (b) jsou oranžovými čarami naznačeny průniky řezů, pokud by nebyla vytvořena 3D maska, tato data by byla započítána dvakrát, což je statistická chyba při vzorkování.

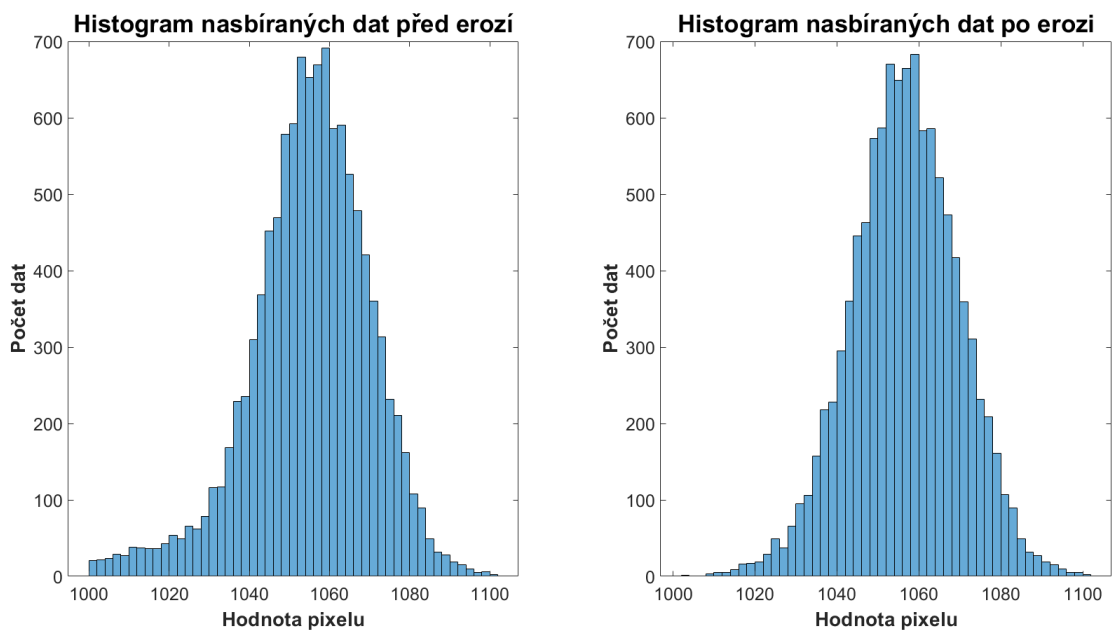
Základní schéma postupu při segmentaci přehledně ukazuje Obr. 6.3. Jak je uvedeno ve schématu, řezy se vybíraly náhodně, nicméně pokud na daném řezu byla tkáň opravdu velmi špatně rozpoznatelná, vybral se jiný řez.



Obr. 6.3: Schéma postupu při segmentaci.

Segmentace 2D řezů probíhala v MATLAB (verze R2016b) aplikaci *Image Segmenter*, která nabízí poloautomatickou segmentaci prostřednictvím nástrojů popsanych v kap. 3. Tato aplikace umožňuje dobrou vizuální kontrolu nad segmentací. Oblast objektu je zvýrazněna žlutou barvou, přičemž jí lze nastavit různou průhlednost. Díky tomu bylo možné efektivně kontrolovat, zda vybraná oblast odpovídá tkáni. Výsledek segmentace lze pomocí aplikace exportovat do 2D masky.

Při segmentaci jakékoliv tkáně se ukázalo vhodné výslednou masku erodovat a to strukturním elementem tvaru kruhu o poloměru aspoň jeden pixel. Tímto krokem byly odstraněny hraniční pixely, u kterých můžeme mít pochyb, zda nesou informaci o dané tkáni, o tkáni vedlejší nebo o obou tkáních zároveň (tzv. „partial volume effect“). Zlepšení výběru dané tkáně ukazuje Obr. 6.4.



Obr. 6.4: Levý histogram ukazuje, jakých hodnot nabývaly pixely po segmentaci ledviny aktivními konturami. V levé části tohoto histogramu je patrný nepřirozený nárůst hodnot, který je dán hraničními hodnotami mezi ledvinou a viscerálním tukem. Na pravém histogramu je vidět, jakých hodnot nabývaly pixely po erozi masky strukturním elementem tvaru kruhu o poloměru jeden pixel. Výběr tkáně je znatelně lepší. Hodnota pixelu je dána CT číslem, nicméně jelikož byla data uložena jako neznaménkové celé číslo, hodnoty pixelů nenabývaly -1024 až 3071 , ale 0 až 4995 (0 tedy například odpovídá vzduchu).

6.1.1 Segmentace měkkých tkání

Měkké tkáně jsou na obraze zobrazeny podobným odstínem šedi, tzn. jejich pixely nabývají podobných hodnot. Poloautomatickou segmentací sice bylo možné dosáhnout přibližného výběru tkáně, nicméně výsledek segmentace vyžadoval značné ruční úpravy.


Výhodným algoritmem pro segmentaci měkkých tkání mohou být aktivní kontury, konkrétně „region-based“ přístup. „Edge-based“ přístup selhával, jelikož mezi měkkými tkáněmi a pozadím byl poměrně malý gradient. Výhodou aktivních kontur je nejen to, že vytváří souvislé oblasti, ale i to, že rozvíjí určitý počáteční tvar, který byl zadán a který přibližně odpovídá tvaru tkáně. V blízkosti vysokodenzitních oblastí však tento algoritmus selhával, jelikož tyto oblasti buď zahrnoval do objektu (případ tepenné krve, kdy do objektu byly zahrnovány i aterosklerotické pláty), nebo tyto oblasti tvořily objekt místo požadované tkáně (případ segmentace tkání v blízkosti obratlů, kdy se původní kontura zcela přesunula do oblasti obratle). Tyto problémy jsou logickým důsledkem fungování „region-based“ aktivních kontur. Tkáň je obklopena pixely s nižšími (viscerální tuk) a v tomto případě i vyššími hodnotami (kosti, aterosklerotické pláty, atd.) pixelů. Z Obr. 3.2 je patrné, že kontura se snaží minimalizovat rozptýlení hodnot uvnitř a vně kontury, čehož může docílit pouze tak, že tkáň přiřadí do té samé oblasti buď s nízkodenzitními, nebo vysokodenzitními strukturami.

V případě problémů s aktivními konturami lze využít metodu narůstání oblastí. Tato metoda sice vytvářela souvislou oblast, ale často nerealistického tvaru, proto bylo potřeba masku dále upravovat například jejím uzavřením, odstraněním oblasti objektu, která přetekla do jiné vedlejší tkáně, atd. Segmentaci meziobratlové ploténky z frontálního řezu ukazuje Obr. 6.5.

6.1.2 Segmentace kostních tkání

K segmentaci kostních tkání (konkrétně kompaktní a spongiózní kosti) použila tato práce těla obratlů. Dostupné segmentační metody se ukázali pro výběr kompaktní kosti jako nedostačující, jelikož buď nebyla vybrána celá tkáň, nebo docházelo k přetečení do spongiózní kosti. Proto bylo potřeba masku dále upravovat tak, aby došlo k odlišení obou kostních tkání.


První krok segmentace spočíval v určení vnější hranice kompaktní kosti. Jako vhodné se jevily aktivní kontury založené na detekci hran, ty však selhávaly v případech špičatých rohů obratle (vyskytujících se hlavně na sagitálních a frontálních snímcích). Kontura na těchto rozích totiž nebyla zachycena a pokračovala dále směrem do obratle, zřejmě z důvodu minimalizace celkové energie kontury. Pro nalezení vnější hranice kompaktní kosti byla tedy nakonec zvolena metoda narůstání oblastí, kdy se semínko umístilo do místa kompaktní kosti a nastavila se dostatečná tolerance, aby byla zachycena i méně denzitní kompaktní kost. Vnitřní hranice sice nebyla použitelná díky prosakování do denzitivnější spongiózní kosti, nicméně vnější hranici kompaktní kosti se tímto způsobem podařilo určit. V celé masce pak byly vyplněny díry a byla uložena jako m_{ext} .



Obr. 6.5: Obrázky (a) až (c) ukazují pokus o segmentaci meziobratlové ploténky, kdy na obrázku (a) je uživatelem určena počáteční kontura, která přibližně odpovídá meziobratlové ploténce. Obrázky (b), resp. (c) jsou výsledkem regionově založeného algoritmu aktivních kontur po 30, resp. 90 iteracích zobrazené v detailu. Je patrné, že segmentace se vůbec nezdařila, oblast objektu se zcela přesunula do oblasti obratle. Na obrázku (d) byla aplikována metoda narůstání oblastí s tolerancí ± 40 . Je vidět, že segmentace neproběhla úplně nejlépe, nicméně dostáváme lepší výsledek než s aktivními konturami. Pokud masku invertujeme (e), můžeme ručně odstranit oblasti přetečení (f). Pokud masku opět invertujeme a aplikujeme morfologickou operaci uzavření, dostáváme již poměrně uspokojivý výsledek na obrázku (g). Pro větší jistotu, že všechny pixely vybrané oblastí tvoří danou tkáň, se maska erodovala (h). Obrázky (e) až (h) jsou opět zobrazeny v detailu.

Druhý krok obnášel zjištění vnitřní hranice kompaktní kosti. Empiricky bylo zjištěno, že pokud erodujeme masku m_{ext} strukturálním elementem tvaru kruhu o poloměru 3 pixely, poměrně přesně určíme vnitřní hranici kompaktní kosti – tato maska byla uložena jako m_{int} . Případné nepřesnosti v určení vnější i vnitřní hranice bylo samozřejmě nutné sledovat a případně ručně upravit.

Maska kortikální kosti pak byla získána jako rozdíl m_{ext} a m_{int} , masku spongiózní kosti tvoří m_{int} . Obě výsledné masky přitom byly erodovány natolik, aby byly z nasbíraných dat vyloučeny ty hraniční pixely mezi kompaktní a spongiózní kostí, o kterých s jistotou nemůžeme říct, do které ze tkání patří. Segmentaci kostních tkání ukazuje Obr. 6.6.



Obr. 6.6: Segmentace kostních tkání pomocí metody narůstání oblastí a dalších úprav. Na obrázku (a) je vidět nízká zvolená tolerance, kdy méně denzitní kompaktní kost ve spodní části těla obratle není do oblasti objektu zařazena. Již při této toleranci však začíná docházet k prosakování do spongiózní kosti. Na obrázku (b) je již dostačující tolerance k tomu, aby byla zachycena celá kompaktní kost. V masce byly vyplněny díry, čímž byla získána finální maska m_{ext} (c). Vhodnou erozí masky m_{ext} pak byla obdržena maska m_{int} (d), jejíž okraje by měly vyjadřovat vnitřní hranici kompaktní kosti. Odečtením masky m_{int} od m_{ext} byla vytvořena maska kompaktní kosti (e).

6.2 Sběr dat a jejich uložení do databáze

Segmentace tkáně byla pečlivě prováděna pouze na kCT obrazech, jelikož výsledek segmentace byl uložen ve formě binární 3D masky. Vynásobením této masky s dalšími objemy dat pak bylo možné získat potřebné údaje o tkáni na kCT obrazu i napříč spektrem energií VMI. Zmíněná 3D maska však byla před finálním sběrem dat ze všech parametrických obrazů ještě upravena, což popisují následující odstavce. Jelikož se nadále hovoří o objemech dat a nikoliv o 2D obrazech, změnilo se v textu označení *pixely* na *voxely*.

Předně byly z nasbíraných dat odstraněny velmi odlehle hodnoty, které zřejmě nepopisují danou tkáň (předpokládá se špatná segmentace či impulsní šum v obraze) a to podle následujícího postupu:

- 1) Pro daná data byly určeny oba kvartily $Q_{0,25}$ a $Q_{0,75}$ a spočítáno mezikvartilové rozpětí IQR jako $Q_{0,75} - Q_{0,25}$.

- 2) Pokud byla hodnota voxelu menší než $Q_{0,25} - 3 \cdot IQR$, byla odstraněna z dat reprezentujících tkáň. Na pozici voxelu ve 3D masce byla přiřazena hodnota 0.
- 3) Pokud byla hodnota voxelu větší než $Q_{0,75} + 3 \cdot IQR$, byla odstraněna z dat reprezentujících tkáň¹. Na pozici voxelu ve 3D masce byla přiřazena hodnota 0.

Dále byla data redukována na počet 25 000 a to náhodným výběrem z dostupných dat (3D maska byla opět aktualizována, aby obsahovala pouze 25 000 jednotek). Přitom bylo kontrolováno rozložení, průměr, medián a směrodatná odchylka u původních a vybraných dat. U všech tkání se medián původních a vybraných dat stoprocentně shodoval, průměry se odlišovaly méně než o 0,08 % a směrodatné odchylky méně než o 0,3 %. Tyto výsledky práce chápe tak, že redukce počtu dat dané tkáně prakticky neovlivnila její statistické charakteristiky.

Po těchto úpravách byla již 3D maska připravena na sběr dat ze všech parametrických obrazů. Byl vytvořen skript, který od uživatele požadoval zadat pouze název složky pacienta (ve které se nacházely složky s kCT i s jednotlivými energiemi VMI) a jeho výstupem byla tabulka obsahující všechny objemy dat, jak ukazuje Obr. 6.7. Požadovaná data pak byla získána součinem 3D masky a vybraného objemu dat.

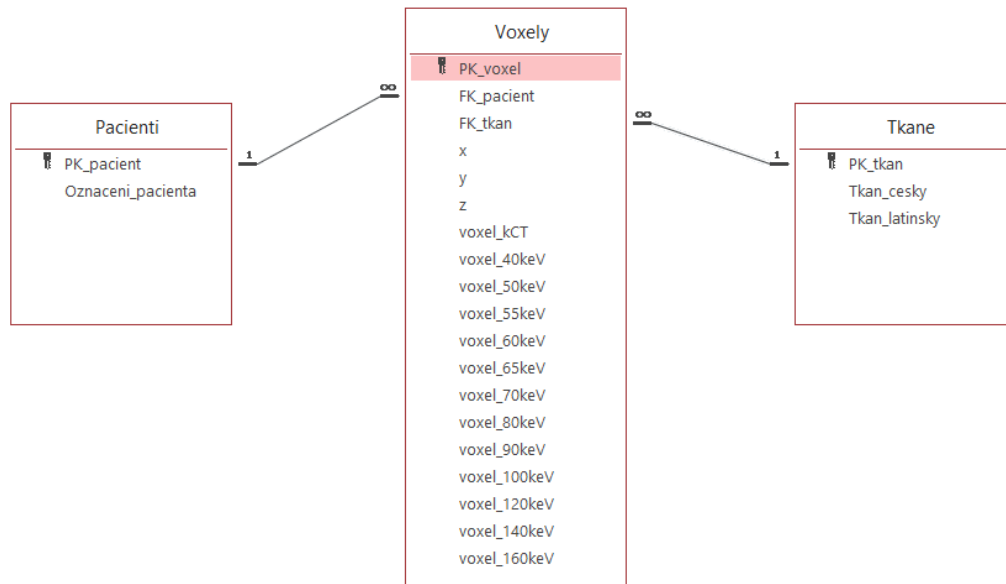
1	2
Parametricky_obraz	Objem_dat
'kCT'	512x512x244 uint16
'MonoE 40keV'	512x512x244 uint16
'MonoE 50keV'	512x512x244 uint16
'MonoE 55keV'	512x512x244 uint16
'MonoE 60keV'	512x512x244 uint16
'MonoE 65keV'	512x512x244 uint16
'MonoE 70keV'	512x512x244 uint16
'MonoE 80keV'	512x512x244 uint16
'MonoE 90keV'	512x512x244 uint16
'MonoE 100keV'	512x512x244 uint16
'MonoE 120keV'	512x512x244 uint16
'MonoE 140keV'	512x512x244 uint16
'MonoE 160keV'	512x512x244 uint16

Obr. 6.7: Tabulka načtených objemů dat.

Tímto postupem vzniklo velké množství dat, které bylo potřeba přehledně uchovat. K tomuto účelu byla vytvořena databáze a to v Microsoft Access, kterou studentům VUT zdarma nabízí v rámci balíku Office 365. Tato databáze, pojmenovaná *DatabazeSpektralnichDat14pacientu*, sestává ze tří tabulek, které jsou v relaci, jak ukazuje Obr. 6.8. Tabulka *Voxely* nesla hlavní informace – byly zde uloženy hodnoty

¹Tento krok nebyl aplikován u spongiózní kosti, kde by se jím odstranili stovky dat (namísto běžných jednotek dat). Takové množství práce chápe tak, že hodnoty vyhodnocené jako odlehle tímto postupem, zřejmě tkáň stále charakterizují, a proto nebyly odstraněny.

daného voxelu při kCT i daných energiích, dále jeho souřadnice x , y , z a poté údaj od jakého pacienta a z jaké tkáně voxel pochází. Údaje o pacientovi byly uloženy v samostatné tabulce *Pacienti*, přičemž tato tabulka je propojena s tabulkou *Voxely* relací 1:N, jelikož daný voxel může pocházet pouze z jednoho pacienta, nicméně u jednoho pacienta můžeme mít data z více voxelů. Údaje o tkáních byly uloženy zvlášť v tabulce *Tkane*, přičemž mezi ní a tabulkou *Voxely* opět existuje relace 1:N, jelikož daný voxel může pocházet pouze z jedné tkáně, nicméně jedna tkáň může sestávat z více voxelů.



Obr. 6.8: Návrh databáze.

Tabulky *Pacienti* a *Tkane* bylo možné naplnit daty ručně přímo v MS Access, nicméně data pro naplnění tabulky *Voxely* byla natolik objemná, že je bylo potřeba přetáhnout z MATLABu. Aby nenastaly problémy mezi převodem dat z jednoho prostředí do druhého, bylo nutné podobu dat upravit tak, aby v obou prostředích byla stejná. U každé tkáně byla tedy v MATLABu vytvořena tabulka, která měla atributy stejné jako tabulka *Voxely* a záznamy tvořily informace z jednotlivých nasbíraných voxelů tkáně. Takto upravená data pak nebyl problém nahrát do tabulky *Voxely* v databázi. Nicméně k tomu bylo nejprve nutné komunikačně propojit MATLAB s MS Accessem, k čemuž bylo potřeba vytvořit ODBC² ovladač pomocí Ovládacích panelů systému Windows. Tento ovladač tvořil jakéhosi prostředníka mezi MATLABem a MS Accessem, a proto bylo možné data přehrát z MATLABu do databáze. Stejně tak pak bylo možné nahrát data z databáze do MATLABu.

²ODBC („Open Database Connectivity“) je standartní rozhraní Microsoft Windows, které umožňuje komunikaci mezi systémem řízení báze dat (systém, který přijímá požadavky v jazyce SQL a převádí je na aktivity databáze [22, s. 29]) a jinými softwarovými aplikacemi [26].

7 Charakterizace tkání

Zkoumanými tkáněmi byla játra, ledvina, slinivka břišní, slezina, žlučník, plíce, tepenná a žilní krev, mícha a koňský ohon¹, velký bederní sval, meziobratlová ploténka, kompaktní a spongiózní kost.

Všechny měkké tkáně na obraze odpovídajícímu klasickému CT (kCT) nabývaly normálního rozložení. Spongiózní kost vykazovala rozložení podobné normálnímu, nicméně objevovalo se zde i značné množství vysokých hodnot, které způsobily, že výsledné rozložení mělo kladnou šikmost (tj. většina hodnot se nacházela pod průměrem). Kompaktní kost definovalo nenormální rozložení dat s kladnou šikmostí. Důvod nenormálního rozložení u kostních tkání může být dvojitý:

- 1) Kost RTG záření zeslabuje mnohem více než měkké tkáně, proto i malá změna v její tloušťce může způsobit značnou změnu v naměřeném útlumu prošlého RTG záření. Pokud v určitém místě tvoří kompaktní kost o něco tlustší vrstvu než všude jinde, získáme z tohoto místa vyšší hodnoty způsobující šikmost dat.
- 2) Různý obsah minerální složky v daném místě kosti činí kost různě tvrdou. Pokud dojde v nějakém místě kosti ke zvýšené akumulaci minerálních solí, získáme z tohoto místa vyšší hodnoty způsobující šikmost dat.

Na monoenergetických obrazech rozložení tkání zůstávalo stejné, nicméně měnily se míry variability i polohy. Největší směrodatná odchylka byla vždy na obraze VMI 40 keV, na kterém se výrazně projevil šum získaný během procesu zobrazování. Co se týče mediánu, bylo zjištěno, že u některých tkání s rostoucí energií VMI hodnota mediánu roste, naopak u jiných tkání klesá. Nelze však obecně říci, které tkáně patří do jaké skupiny, jelikož medián CT čísla dané tkáně může u jednoho pacienta růst a u druhého klesat. To může být způsobeno různou tělesnou konstitucí pacientů, proto je důležité porovnávat charakteristiky tkáně u vybraného pacienta. Charakterizace tkání dále prokázala, že růst či pokles mediánu je u různých tkání různě strmý, což může pomoci při jejich klasifikaci.

Tato práce zkoumala kontrastní rozlišení vybraných dvojic tkání, které leží blízko anatomicky u sebe, konkrétně velký bederní sval / meziobratlová ploténka, tepenná krev / žilní krev, mícha / koňský ohon, játra / ledvina a kompaktní kost / spongiózní kost.

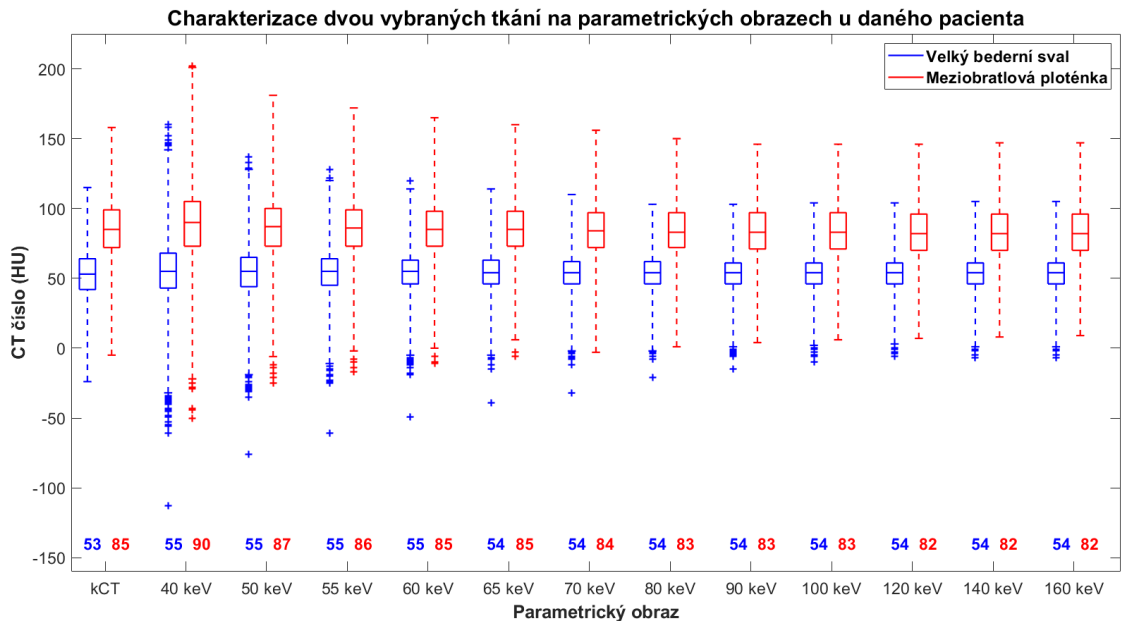
Odlišnost vybrané dvojice tkání na daném parametrickém obraze se řídí dvěma základními pravidly:

- 1) Čím větší rozdíl mediánů, tím lépe tkáně rozeznáme.
- 2) Čím menší směrodatná odchylka, tím lépe tkáně rozeznáme.

¹U dospělého koně mícha mezi obratli L1 a L2, dále pokračují jen nervové kořeny označované jako koňský ohon (cauda equina) [28, s. 272].

Obě tato pravidla jsou zakomponována ve výpočtu metriky velikosti účinku („effect size“). Pomocí vybrané metriky pak můžeme posoudit, který parametrický obraz poskytuje nejlepší kontrastní rozlišení tkání.

Měkké tkáně nabývaly normálního rozložení, proto jejich mediány můžeme nahradit průměry a použít Cohenovo d. Pro tkáně s nenormálním rozložením lze použít Cliffovo delta. Příklad určení VMI s nejlepším kontrastem mezi velkým bederním svaem a meziobratlovou ploténkou u daného pacienta ukazuje Obr. 7.1 a Tab. 7.1.



Obr. 7.1: Krabicové grafy zobrazují charakterizaci vybrané dvojice tkání na jednotlivých parametrických obrazech – střed krabice je medián, okraje krabice tvoří horní a dolní kvartil, fousky jsou délky trojnásobku mezikvartilového rozpětí a pluska značí velmi odlehlé hodnoty. Data jsou přitom upravena tak, aby graf zobrazoval CT čísla místo hodnot pixelů (získáno odečtením 1024). Zcela vlevo je vidět charakterizace tkání na referenčním kCT obraze, následují charakterizace na jednotlivých VMI o dané energii. Medián CT čísla velkého bederního svalu i meziobratlové ploténky na těchto obrazech s rostoucí energií klesá, resp. neroste, jak je vidět nejen z krabicových grafů, ale i mediánů barevně vypsaných ve spodní části. Dále je patrné, že u svalu je strmost poklesu mediánu CT čísla mnohem menší než u meziobratlové ploténky. Tento charakter vybraných tkání není však pravidlem u všech pacientů.

	kCT	40 keV	50 keV	55 keV	60 keV	65 keV	70 keV	80 keV	90 keV	100 keV	120 keV	140 keV	160 keV
VBS/MP	1,806	1,513	1,740	1,855	1,929	1,973	1,994	2,003	1,995	1,981	1,959	1,942	1,932

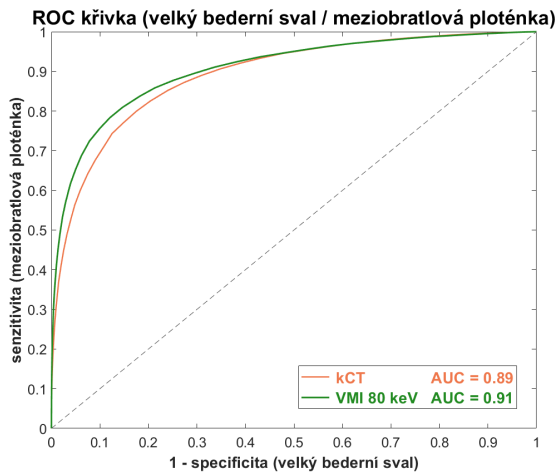
Tab. 7.1: Cohenovo d pro dvojici tkání z Obr. 7.1, přičemž zelená barva je u parametrického obrazu, který nabízí nejlepší rozlišení dané dvojice. VBS/MP = velký bederní sval / meziobratlová ploténka.

Obecnější představu o tom, který VMI nabízí nejlepší kontrastní rozlišení vybrané dvojice tkání, lze získat zprůměrováním velikostí účinku skrze všechny pacienty (Tab. 7.2). Úspěšnost klasifikace vybraných tkání pak může být s pomocí

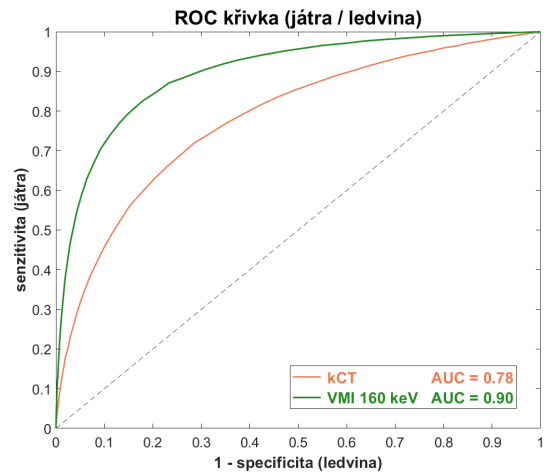
tohoto obrazu větší, než kdyby se použil kCT obraz, jak podrobně dokládají ROC křivky (Obr. 7.2). Podmínkou však je, aby se velikost účinku na VMI dostatečně lišila od kCT obrazu a dále aby její hodnota byla dostatečně velká. Pokud by bylo Cohenovo d menší než 0,8 (resp. Cliffovo delta menší než 0,47), nedosáhneme dobré klasifikace ani s pomocí VMI (histogramy tkání se v tomto případě překrývají více než o 50 %).

	kCT	40 keV	50 keV	55 keV	60 keV	65 keV	70 keV	80 keV	90 keV	100 keV	120 keV	140 keV	160 keV
VBS/MP	1,819	1,447	1,758	1,883	1,973	2,030	2,079	2,102	2,100	2,033	1,994	1,982	1,947
TK/ŽK	0,124	0,209	0,200	0,192	0,182	0,172	0,170	0,151	0,156	0,143	0,140	0,144	0,137
M/KO	0,277	0,276	0,306	0,314	0,321	0,325	0,326	0,325	0,330	0,316	0,309	0,304	0,301
J/L	1,328	1,029	1,323	1,447	1,543	1,611	1,657	1,799	1,786	1,826	1,890	1,922	1,958
KK/SK	0,96207	0,94773	0,95447	0,95718	0,95940	0,96112	0,96246	0,96481	0,96484	0,96491	0,96465	0,96418	0,96489


Tab. 7.2: Průměrná velikost účinku (Cohenovo d pro měkké tkáně, Cliffovo delta pro kostní tkáně) pro vybrané dvojice tkání. Cliffovo delta má menší rozsah než Cohenovo d , a proto je uváděno s větší přesností. Zeleně je vyznačen VMI, který poskytuje nejlepší kontrastní rozlišení pro danou dvojici. VBS/MP = velký bederní sval / meziobratlová ploténka, TK/ŽK = tepenná krev / žilní krev, M/KO = mícha / koňský ohon, J/L = játra / ledvina, KK/SK = kompaktní kost / spongiózní kost. Data dvojice VBS/MP a J/L byla nasbírána u 13 pacientů, TK/ŽK u 11 pacientů, M/KO u 9 pacientů a KK/SK u 5 pacientů.




(a)




(b)



(c)



(d)



(e)

Obr. 7.2: ROC křivky vybraných dvojic tkání. Čím větší rozdíl mezi velikostí účinku na VMI a kCT obrazu, tím větší zlepšení AUC (a, b). U kostních tkání je rozdíl mezi kCT a VMI obrazem nepatrný, a proto se ROC křivky překrývají (c). Pokud je velikost účinku velmi malá, nepomůže k lepší klasifikaci ani VMI (d, e).

8 Klasifikace tkání

Na klasických CT obrazech jsme již dnes schopni určité tkáně automaticky dobře klasifikovat (např. plíce versus ostatní měkké tkáně), jiné tkáně jsou však odlišitelné hůře a spoléháme se pouze na anatomické znalosti. Charakterizace tkání na jednotlivých parametrických obrazech prokázala, že některé VMI nabízí lepší kontrastní rozlišení vybrané dvojice tkání než klasický CT obraz. S pomocí vhodných VMI tedy dokážeme podobné tkáně od sebe lépe odlišit.

Podmínkou dobré klasifikace je dostatečně velká hodnota velikosti účinku. U dvojice tepenná krev / žilná krev a mícha / koňský ohon byla na všech parametrických obrazech zaznamenána velmi malá velikost účinku. Úspěšnost klasifikace zde byla dle očekávání velmi nízká (příloha A), a to i v případě, že se ke klasifikaci využilo více příznaků (více energií VMI). Naopak u ostatních dvojic byla dobrá šance na jejich rozlišení, a proto se práce jejich klasifikací zabývala detailněji.

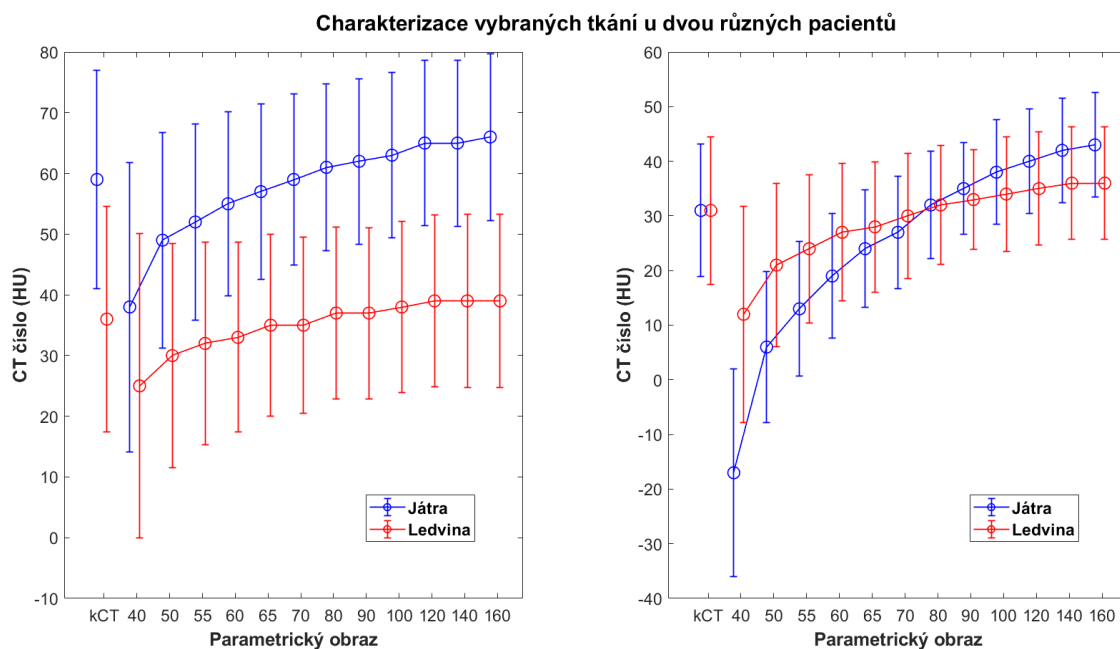
Pro automatickou klasifikaci byl zvolen algoritmus náhodného lesa („Random Forest“), jehož přednosti byly uvedeny v teoretické části. Počet stromů byl nastaven jako 20 na základě analýzy „out of bag“ chyby při různých počtech stromů. Trénovací data byla čerpána z vytvořené databáze dat, testovacími daty pak byla náhodně vybraná část obou tkání na náhodném snímku (avšak jiném, než na kterém byla sbírána trénovací data) u daného pacienta. Snahou bylo dosáhnout dobré klasifikace s využitím co nejméně parametrických obrazů z důvodu menší výpočetní a časové náročnosti.

Klasifikace na základě samotných pixelů

Klasifikace tkání na základě jednotlivých pixelů dosahovala s využitím vhodných VMI lepší úspěšnosti než na kCT obrazu (Tab. 8.1). Ve většině případů stačil ke klasifikaci pouze jeden VMI a to ten s nejlepší velikostí účinku (Tab. 7.2). U dvojice játra / ledvina však bylo ve třech případech z třinácti výhodné použít dva VMI, jelikož charakteristiky tkání se křížily, jak je vidět na Obr. 8.1. Pro zajímavost byla vyzkoušena i klasifikace s využitím všech VMI, která byla srovnána s klasifikací pomocí vybraných VMI. V některých případech bylo dosaženo zlepšení klasifikace o jednotky procent, jindy naopak nastalo zhoršení – úspěšnost klasifikace zde záležela na pozici konkrétních pixelů ve 13D prostoru (13 energií VMI). Prakticky však klasifikace s využitím všech VMI nemá význam, jelikož jejich rekonstrukce pro každého pacienta by byla zdlouhavá. Lepším směrem je zaměřit se na zlepšení klasifikace s využitím pouze vybraných VMI.

	kCT	vybrané VMI	všechny VMI
velký bederní sval	84,48 ± 0,13	88,64 ± 0,12	89,58 ± 0,15
meziobratlová ploténka	79,05 ± 0,27	82,68 ± 0,28	86,06 ± 0,30
játra	75,05 ± 0,39	90,29 ± 0,17	91,49 ± 0,19
ledvina	73,78 ± 0,40	88,92 ± 0,22	89,75 ± 0,24
kompaktní kost	94,84 ± 0,28	94,45 ± 0,24	94,28 ± 0,22
spongiózní kost	97,02 ± 0,34	97,62 ± 0,32	96,73 ± 0,36

Tab. 8.1: Úspěšnost klasifikace na základě samotných pixelů udaná v procentech. U dané dvojice tkání byla vždy vypočítána senzitivita (resp. specificita) pro první (resp. druhou) tkáň a výsledky byly zprůměrovány pro všechny pacienty. Kromě samotného průměru je uvedena i střední chyba průměru. Je patrné, že VMI zlepšují úspěšnost klasifikace měkkých tkání oproti kCT obrazu. U kostních tkání je úspěšnost klasifikace na VMI a kCT obrazu téměř totožná, což jen potvrzuje výsledek na Obr. 7.2(c). Uplatnění všech VMI k lepší klasifikaci zásadně nepřispívá.



Obr. 8.1: Různé průběhy charakteristik u různých pacientů – pro zjednodušení je zakreslen pouze medián (kroužkem) a směrodatná odchylka (fousky). Čísla na ose x značí energie VMI v keV. Vlevo je typický průběh charakteristik tkání, vpravo je výjimečné křížení charakteristik. Na metrice velikosti účinku lze toto křížení poznat tak, že se po křížení změní její znaménko. V případě křížení bylo pro klasifikaci výhodnější použít jak obraz s nejlepší velikostí účinku (v absolutní hodnotě), tak obraz s nejlepší velikostí účinku za křížením. Typicky se jednalo o VMI 40 keV a 160 keV.

Klasifikace na základě mediánu regionu pixelů

Mnohem lepších výsledků klasifikace bylo dosaženo, pokud byly místo samotných pixelů využity statistické charakteristiky tkáně, konkrétně medián. Rozložení mediánů, které získáme výpočtem mediánu vždy z určitého regionu pixelů, má totiž

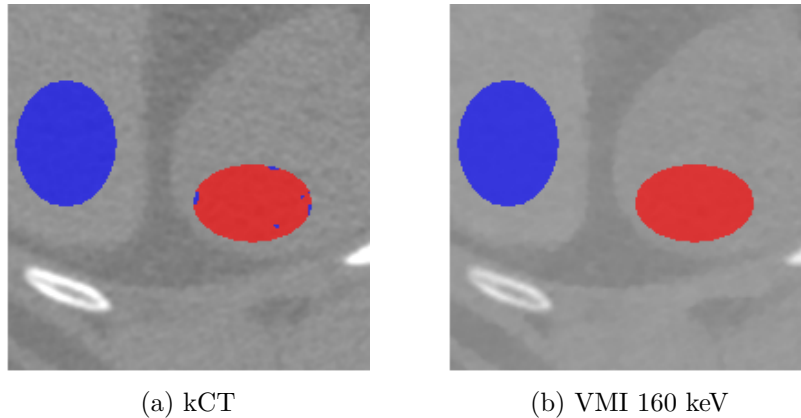
mnohem menší variabilitu než rozložení samotných pixelů. Jiné statistické charakteristiky jako průměr či směrodatná odchylka nejsou ke klasifikaci tak vhodné jako medián, jelikož jejich variabilita je vyšší díky větší citlivosti na odlehlé hodnoty v datech.

Trénovací data byla vytvořena mediánovou filtrací dat dané tkáně uložených v databázi. Testovací data byla získána vypočtením mediánu z hodnot získaných ze samotného pixelu, který chceme správně zařadit, a jeho kruhového okolí. Přitom platí, že počet dat, ze kterých se počítal medián u trénovacích i testovacích dat je stejný. Cílem je dosáhnout dobré klasifikace s co nejmenším kruhovým okolím. Nastavení poloměru tohoto okolí při klasifikaci měkkých tkání probíhalo individuálně pro daný snímek. Pokud klasifikace nedosáhla stoprocentní úspěšnosti ani s poloměrem 20 pixelů, dále se nepokračovalo a byla zaznamenána úspěšnost při tomto okolí. Pro srovnání: průměrný poloměr meziobratlové ploténky činil na axiálním snímku 70 pixelů. U kostních tkání byla nastavována konstantní hodnota poloměru kruhového okolí dva pixely. Je to z toho důvodu, aby úzká kompaktní kost byla klasifikátorem vůbec zachycena.

Tímto postupem klasifikace bylo dosaženo dobrých výsledků nejen na VMI, ale i na kCT obraze. Pro správnou klasifikaci na tomto obraze však zpravidla musel být medián vypočten z většího okolí, což by ztěžovalo detekci menších útvarů jako jsou cévy probíhající tkání, cysty, nádory, apod. Srovnání klasifikace na základě mediánu regionu pixelů s využitím vhodných VMI a kCT obrazu nabízí Tab. 8.2.

	kCT	VMI
velký bederní sval	99,63 ± 0,03	99,86 ± 0,01
meziobratlová ploténka	99,25 ± 0,06	99,71 ± 0,03
játra	89,29 ± 0,55	99,82 ± 0,03
ledvina	92,72 ± 0,36	98,86 ± 0,18
kompaktní kost	94,82 ± 0,25	95,33 ± 0,22
spongiózní kost	98,12 ± 0,26	98,75 ± 0,22


Tab. 8.2: Úspěšnost klasifikace na základě mediánu regionu pixelů udaná v procentech. U dané dvojice tkání byla vždy vypočítána senzitivita (resp. specificita) pro první (resp. druhou) tkáň a výsledky byly zprůměrovány pro všechny pacienty. Kromě samotného průměru je uvedena i střední chyba průměru. Poloměr kruhového okolí byl u kostních tkání nastaven jako dva pixely, u měkkých tkání v rozsahu tři až dvacet pixelů. Úspěšnost klasifikace s využitím kCT a VMI přitom byla na daném snímku hodnocena vždy při stejném okolí. Průměrná velikost poloměru okolí potřebného pro správnou klasifikaci tkání činila u dvojice játra / ledvina osm pixelů, u dvojice velký bederní sval / meziobratlová ploténka deset pixelů. Z tabulky je patrné, že při daném poloměru kruhového okolí dosahovala klasifikace pomocí vybraných VMI lepší úspěšnosti než na kCT obraze.



Obr. 8.2: Poloměr kruhového okolí byl nastaven na 10 pixelů. Na VMI je úspěšnost klasifikace sto-procentní, na kCT obrazu jsou některé pixely zařazeny stále chybně. Pro jejich správnou klasifikaci by bylo potřeba zvětšit poloměr kruhového okolí.


Klasifikace na základě regionu pixelů se dobře uplatní u velkých tkání, kde lze nastavit dostatečně velké okolí, ze kterého se medián počítá. Pokud jsou tkáně úzké, jak je tomu např. u kompaktní kosti, je potřeba nastavovat dostatečně malé okolí, aby úzká tkáň byla vedle širší tkáně vůbec zachycena. Avšak čím menší okolí, tím více se úspěšností přibližujeme ke klasifikaci pomocí samotných pixelů.

Další limitací této metody, kterou naznačuje Obr. 8.3, je skutečnost, že mezi tkáněmi vytváří mnohdy nerealistickou hranici (zejména v případech velmi konvexních hranic) jako je např. u dvojice meziobratlová ploténka/velký bederní sval, jak je vidět na Obr. 8.4(b)).



Obr. 8.3: Červeně a modře je naznačena vybraná dvojice tkání, mezi nimiž chceme určit realistickou hranici. Zkoumaný pixel (označen křížkem) bude po výpočtu mediánu z daného okolí pixelu zařazen špatně, jelikož vybraný region obsahuje více pixelů jiné tkáně, než do které zkoumaný pixel patří.

Čím menší okolí pixelu při tvorbě mediánu bylo uvažováno, tím lépe šla pozorovat skutečná hranice, nicméně menší okolí mělo zase negativní vliv na úspěšnost klasifikace (nejmenší možné okolí je nulové, tedy vracíme se k situaci, kdy při klasifikaci uvažujeme samotné pixely – Obr. 8.4(a)). Proto byly přístupy klasifikace na základě samotných pixelů a regionu pixelů zkombinovány – výsledek je vidět na Obr. 8.4(c).



Obr. 8.4: Klasifikace tkání pomocí algoritmu náhodného lesa na vybrané oblasti zájmu s pomocí jednotlivých pixelů (a), regionu pixelů (b) a kombinovaného přístupu vhodného pro určení konvexních hranic (c). Modrá barva odpovídá velkému bedernímu svalu, červená barva meziobratlové ploténce. Ke klasifikaci byl využit VMI 80 keV.

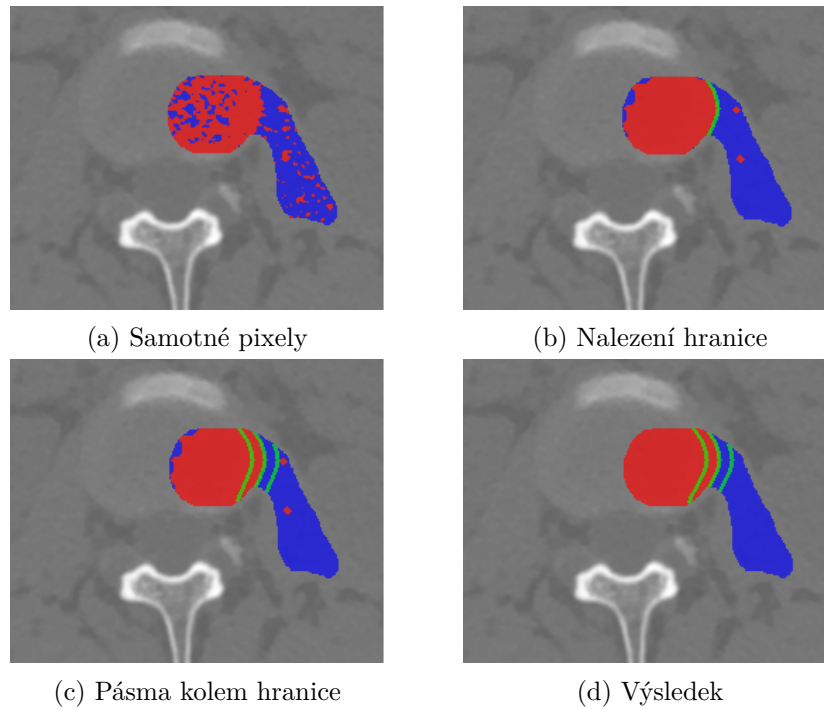
Klasifikace na základě kombinovaného přístupu

Pokud bychom kombinaci přístupů provedli tak, že klasifikátor naučíme na hodnotách samotných pixelů a mediánů pixelů zároveň, obdržíme stejný výsledek jako při klasifikaci na základě mediánu regionu pixelů. Je to z toho důvodu, že rozložení mediánů má mnohem menší variabilitu než rozložení samotných pixelů, a proto ho náhodný les bere jako dominantní příznak při rozhodování o třídě daného pixelu. Proto musely být použity dva klasifikátory – jeden pro klasifikaci samotných pixelů a druhý pro klasifikaci tkání na základě mediánů regionu pixelů.

Nejdříve byly klasifikovány samotné pixely s pomocí VMI, které dávaly nejlepší úspěšnost klasifikace. Pozorovaná hranice však byla nesouvislá, a proto bylo rozhodnuto proložit ji vyhlazujícím splajnem. Pro správné nalezení hranice, která má být vyhlazena, byly učiněny následující kroky:

- 1) Z výsledků klasifikace pomocí samotných pixelů byly vytvořeny binární masky obou tkání. Jedna z těchto masek byla vyhlazena pomocí morfologické operace otevření a následného uzavření. Druhá maska byla doplňkem masky první v univerzu tvořeném oblastí zájmu.
- 2) Byly nalezeny hrany jako možné hranice mezi tkáněmi. Pokud pixel $p(r - 1, s)$ patří dle masek do první tkáně a pixel $p(r + 1, s)$ do druhé tkáně, pak pixel $p(r, s)$ tvoří horizontální hranu. Podobně bylo postupováno i u vertikálních a diagonálních hran.
- 3) Byla nalezena nejdelší hrana, která byla proložena vyhlazujícím splajnem. Pokud RMSE bylo menší než určená limitní hodnota přípustné chyby, byla nalezena správná hranice. V opačném případě byl zřejmě místo hranice nalezen shluk pixelů, které byly kvůli nedokonalé klasifikaci na počátku určeny jako hranice. Tato možnost byla z kandidátů na možné hranice vyloučena a pokračovalo se znovu od začátku tohoto bodu, dokud nebyla nalezena vyhovující hranice.

Po nalezení hranice byla vymezena dvě úzká pásma kolem hranice (jedno nad a jedno pod hranicí), kde byly pixely zařazeny podle majoritní skupiny pixelů v tomto pásmu. Šířka tohoto pásma byla rovna poloměru kruhového okolí, ze kterého se následně bude počítat medián. Tímto krokem zajistíme zachování konvexnosti hranice. Pixely mimo hranici a pásma lze následně zařadit již výše popsáním způsobem pomocí mediánu tohoto pixelu a jeho okolí.



Obr. 8.5: Postup při klasifikaci na základě kombinovaného přístupu. Modře je označen velký bederní sval, červeně meziobratlová ploténka. Zeleně je zvýrazněná hranice mezi tkáněmi, resp. hranice dvou přilehlých pásem. Byl použit VMI 80 keV a poloměr okolí 9 pixelů.

9 Diskuze

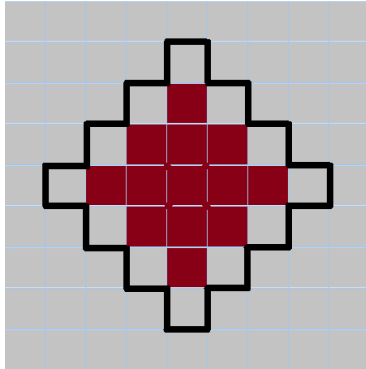
Spektrální CT přineslo možnost rekonstrukce různých parametrických obrazů. Využití těchto obrazů při diagnostice je předmětem výzkumu posledních několika let. V srpnu 2017 Doerner a kol. publikovali článek [10], ve kterém uvádí, že VMI zlepšují kvalitu obrazu ve srovnání s polyenergetickými obrazy (tedy s kCT obrazy). Zároveň však dodává, že stále není známo, zda VMI přináší další diagnostické informace. Leithner a kol. ještě téhož roku konstatovali, že VMI zlepšuje diagnostiku plicní embolie [23], Chalian a kol. pak například uvádí, že pomocí VMI lze zlepšit posouzení anatomie a patologie aorty [9]. Poslední článek o VMI, který tato práce zaznamenala, byl uveřejněn v lednu tohoto roku (2019) Kikanem a kol., kde je popsáno využití VMI pro 3D segmentaci vybraných tkání (aorta, trombus, trachea, caput humeri) [20]. Tato bakalářská práce se snažila detailněji objasnit, jak se mění statistické charakteristiky tkání napříč spektrem energií vytvořených VMI a jak můžou VMI přispívat ke klasifikaci tkání. V následujících odstavcích jsou výsledky a jejich možné aplikace podrobně diskutovány.

Rekonstruktor parametrických obrazů spektrálního CT nabízí vytvořit velké množství energií VMI. Otázku, kterou energii pro rozlišení daných tkání použít, může zodpovědět charakterizace tkání. Pomocí velikosti metriky účinku lze totiž určit, který VMI je pro kontrastní rozlišení vybrané dvojice tkání nejlepší a jaké zlepšení v kontrastu nastane oproti obrazu z klasického CT. Pokud by byla provedena studie obsahující dostatečné množství CT snímků s vybranou patologií (např. nádorem), bylo by možné pomocí charakterizace tkání určit, na které energii VMI bude tato patologie nejlépe odlišitelná od zdravé tkáně. Charakterizaci tkání lze přitom provést na libovolných parametrických obrazech, proto by se dále mohlo zkoumat kontrastní rozlišení vybraných tkání i na dalších obrazech uvedených v podkap. 5.2.

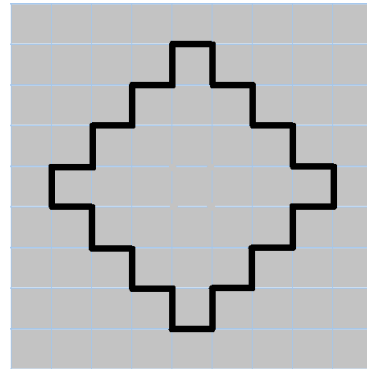
Klasifikace tkání s využitím vhodných VMI dosahovala lepších výsledků než s využitím kCT obrazu, což může při diagnostice hrát důležitou roli. Pokud by totiž bylo záměrem rozlišit patologii od zdravé tkáně, je žádoucí zařadit správně každý pixel. Malá senzitivita klasifikace patologie může vést k jejímu přehlédnutí na CT snímku, naopak malá specificita klasifikace zdravé tkáně lékaře zbytečně často staví před rozhodnutí, zda se opravdu jedná o patologii.

Lepších výsledků klasifikace bylo dosaženo, pokud byl počítán medián z určitého regionu pixelů. Poloměr kruhového okolí byl přitom u měkkých tkání nastavován individuálně pro daný snímek. Pokud by byl poloměr nastaven pro všechny snímky jednotně na nějakou vyšší konstantní hodnotu (aby úspěšnost klasifikace byla vysoká), hrozí přehlédnutí malých oblastí, které se svými statistickými charakteristikami od tkáně liší (patologií). Proto je vhodnější určit minimální poloměr okolí dostatečný pro správnou klasifikaci přímo pro daný snímek. Pokud jsou obě tkáně

na snímku viditelné, senzitivitu i specificitu klasifikace lze při daném poloměru okolí přímo určit. Složitější situace nastává v případě hledané patologie, pokud bychom však znali informaci o denzitě patologie, lze tuto situaci jednoduše vyřešit – místo nádoru lze totiž vybrat jinou tkáň s obdobnou denzitou a senzitivitu klasifikace nádoru určit jako senzitivitu klasifikace právě této tkáně. Poloměry kruhového okolí potřebné pro správnou klasifikaci s využitím VMI a kCT obrazu se lišily o jednotky pixelů, nicméně pro detekci malých útvarů tato skutečnost může mít zásadní vliv, jak ukazuje Obr. 9.1.



(a) Výsledek klasifikace ($r = 3$ pixely)



(b) Výsledek klasifikace ($r = 5$ pixelů)

Obr. 9.1: Výsledek klasifikace na základě výpočtu mediánu z regionu pixelů při různě velkém poloměru kruhového okolí r . Černě je označena oblast nádoru, výsledek klasifikace je zobrazen šedou (zdravá tkáň), resp. červenou (nádor) barvou.

V neposlední řadě lepší kontrastní rozlišení vybraných tkání na VMI vede i k přesnějšímu určení hranice mezi tkáněmi. Toho lze využít při 2D i 3D segmentaci tkání, která může sloužit například k posouzení úbytku parenchymu orgánu či pro výukové účely.

10 Závěr

V rámci této bakalářské práce byla zpracována literární rešerše o spektrálním CT, do kterého práce zahrnovala DECT i MECT. Byla popsána konstrukce obou typů CT, základní algoritmus pro zpracování spektrálních dat i možné lékařské využití těchto modalit.

V praktické části byl navržen postup pro charakterizaci tkání na několika parametrických obrazech. Na dostupných datech bylo prokázáno, že VMI zlepšují kontrastní rozlišení některých měkkých tkání, přičemž míru jejich odlišnosti na daném parametrickém obraze lze posoudit pomocí Cohenova d . Výsledky této práce jsou překvapivé, jelikož bylo očekáváno, že se budou na kontrastním rozlišení měkkých tkání nejvíce podílet nejnižší energie VMI. Pro dvojici játra / ledvina se však jeví jako nejlepší VMI 160 keV, u dvojice velký bederní sval / meziobratlová ploténka je to pak VMI 80 keV. U kostních tkání nedocházelo ve srovnání s kCT obrazem k výraznému zlepšení kontrastu.

Díky faktu, že na vhodných VMI jsou vybrané dvojice tkání lépe rozlišitelné než na kCT obraze, je možné je na těchto obrazech lépe klasifikovat. U dvojice játra / ledvina je vhodné kromě VMI 160 keV rekonstruovat i VMI 40 keV a srovnat mediány tkání na obou obrazech. Pokud dochází ke křížení charakteristik tkání, je doporučeno využít ke klasifikaci i VMI 40 keV, v opačném případě postačuje využít VMI 160 keV.

Účinnější klasifikace bylo dosaženo pokud místo samotných pixelů byly raději uvažovány statistické charakteristiky určitého regionu, přičemž u VMI stačí pro správnou klasifikaci zpravidla menší region než na kCT obraze. To by umožňovalo detekovat ve tkáni menší oblasti, které se svými statistickými charakteristikami od tkáně liší (cévy probíhající tkání, cysty, nádory, apod.). Pokud jde o určení věrohodné hranice mezi tkáněmi, je potřeba kombinovat klasifikaci pomocí samotných pixelů i regionu pixelů. Jestliže dokážeme tuto hranici určit, můžeme tkáně účinně segmentovat.

Literatura

- [1] ALVAREZ, R. E. a A. MACOVSKI. Energy-selective reconstructions in X-ray computerised tomography. *Physics in Medicine and Biology* [online]. 1976, **21**(5), 733–744. [cit. 2018-11-30]. DOI: 10.1088/0031-9155/21/5/002. ISSN 00319155. Dostupné z URL: <http://stacks.iop.org/0031-9155/21/i=5/a=002?key=crossref.9250d07732e8ba4c630ab8afe8ccd214>
- [2] ANDERSON, N. G. a kol. Spectroscopic (multi-energy) CT distinguishes iodine and barium contrast material in MICE. *European Radiology* [online]. 2010, **20**(9), 2126–2134. [cit. 2018-11-30]. DOI: 10.1007/s00330-010-1768-9. ISSN 1432-1084. Dostupné z URL: <https://link.springer.com/article/10.1007/s00330-010-1768-9>
- [3] BELGIU, Mariana a Lucian DRĂGUȚ. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing* [online]. 2016, **114**, 24–31. [cit. 2019-04-23]. DOI: 10.1016/j.isprsjprs.2016.01.011. ISSN 0924-2716. Dostupné z URL: <https://www.sciencedirect.com/science/article/abs/pii/S0924271616000265>
- [4] BERRY, Elizabeth. *A practical approach to medical image processing*. New York: Taylor & Francis, 2008. 288 s. ISBN 978-1-58488-824-6.
- [5] BIRKFELLNER, Wolfgang. *Applied medical image processing: a basic course*. Second edition. Boca Raton: CRC Press, Taylor & Francis Group, 2014. 423 s. ISBN 978-1-4665-5557-0.
- [6] BISHOP, Christopher M. *Pattern recognition and machine learning*. New York: Springer, 2006. 738 s. ISBN 978-0-387-31073-2.
- [7] BRAHME, Anders. *Comprehensive biomedical physics: X-ray and ultrasound imaging*. Volume 2. Amsterdam: Elsevier, 2014. 517 s. [cit. 2018-11-23]. ISBN 978-0-444-53632-7. Dostupné také z URL: https://books.google.cz/books?id=9RR0AAQBAJ&printsec=frontcover&hl=cs&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false
- [8] BUSHBERG, Jerrold T. a kol. *The essential physics of medical imaging*. 3rd ed. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins, 2012. 1030 s. ISBN 978-0-7817-8057-5.
- [9] CHALIAN, Hamid a kol. Utility of virtual monoenergetic images derived from a dual-layer detector-based spectral CT in the assessment of aortic anatomy and pathology: A retrospective case control study. *Clinical Imaging* [online]. 2018,

- 52, 292–301. [cit. 2019-05-11]. DOI: 10.1016/j.clinimag.2018.08.007. ISSN 0899-7071. Dostupné z URL: <http://www.sciencedirect.com/science/article/pii/S0899707118302286>
- [10] DOERNER, Jonas a kol. Image quality evaluation of dual-layer spectral detector CT of the chest and comparison with conventional CT imaging. *European Journal of Radiology* [online]. 2017, **93**, 52–58. [cit. 2018-11-24]. DOI: 10.1016/j.ejrad.2017.05.016. ISSN 0720-048X. Dostupné z URL: <http://www.sciencedirect.com/science/article/pii/S0720048X1730195X>
- [11] FORGHANI, Reza, Bruno DE MAN a Rajiv GUPTA. Dual-Energy Computed Tomography: Physical Principles, Approaches to Scanning, Usage, and Implementation: Part 1. *Neuroimaging Clinics of North America* [online]. 2017, **27**(3), Dual Energy CT: Applications in Head and Neck and Neurologic Imaging, 371–384 [cit. 2018-11-18]. DOI: 10.1016/j.nic.2017.03.002. ISSN 1052-5149. Dostupné z URL: <http://www.sciencedirect.com/science/article/pii/S1052514917300187>
- [12] FORGHANI, Reza, Bruno DE MAN a Rajiv GUPTA. Dual-Energy Computed Tomography: Physical Principles, Approaches to Scanning, Usage, and Implementation: Part 2. *Neuroimaging Clinics of North America* [online]. 2017, **27**(3), Dual Energy CT: Applications in Head and Neck and Neurologic Imaging, 385–400 [cit. 2018-11-18]. DOI: 10.1016/j.nic.2017.03.003. ISSN 1052-5149. Dostupné z URL: <http://www.sciencedirect.com/science/article/pii/S1052514917300199>
- [13] FORNARO, Juergen a kol. Dual- and multi-energy CT: approach to functional imaging. *Insights into Imaging* [online]. 2011, **2**(2), 149–159 [cit. 2018-11-18]. DOI: 10.1007/s13244-010-0057-0. ISSN 1869-4101. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3259372/>
- [14] GONZALEZ, Rafael C. a Richard E. WOODS. *Digital image processing*. New York, NY: Pearson, 2018. 1168 s. ISBN 978-0-13-335672-4.
- [15] GOO, Hyun Woo a Jin Mo GOO. Dual-Energy CT: New Horizon in Medical Imaging. *Korean Journal of Radiology* [online]. 2017, **18**(4), 555–569 [cit. 2018-11-18]. DOI: 10.3348/kjr.2017.18.4.555. ISSN 1229-6929. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5447632/>
- [16] HE, Peng a kol. Material Discrimination Based on K-edge Characteristics. *Computational and Mathematical Methods in Medicine* [online]. 2013 [cit. 2018-11-18]. DOI: 10.1155/2013/308520. ISSN 1748-670X. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3844261/>

- [17] HEISMANN, Björn J., Bernhard T. SCHMIDT a T. FLOHR. *Spectral computed tomography*. Bellingham, Wash: SPIE Press, 2012. 119 s. ISBN 978-0-8194-9257-9.
- [18] HEŘMAN, Miroslav. *Základy radiologie*. Olomouc: Univerzita Palackého, 2014. 314 s. ISBN 978-80-244-2901-4.
- [19] KALAMPOGIAS, Aimilios a kol. Basic Mechanisms in Atherosclerosis: The Role of Calcium. *Medicinal Chemistry (Sharīqah (United Arab Emirates))*. 2016, **12**(2), 103–113 [cit. 2018-11-18]. ISSN 1875-6638. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pubmed/26411606>
- [20] KIKANO, Elias a kol. Utility of virtual monoenergetic images from spectral detector computed tomography in improving image segmentation for purposes of 3D printing and modeling. *3D Printing in Medicine* [online]. 2019, **5**(1), 1. [cit. 2019-05-11]. DOI: 10.1186/s41205-019-0038-y. ISSN 2365-6271. Dostupné z URL: <https://threedmedprint.biomedcentral.com/articles/10.1186/s41205-019-0038-y>
- [21] Koninklijke Philips N.V. IQon Spectral CT | Philips Healthcare. *Spectral CT Learning Center* [online]. ©2004-2018 [cit. 2018-12-25]. Dostupné z URL: <http://www.spectralctlearningcenter.philips.com/>
- [22] KROENKE, David a David J AUER. *Databáze*. Brno: Computer Press, 2015. 496 s. ISBN 978-80-251-4352-0.
- [23] LEITHNER, Doris a kol. Virtual Monoenergetic Imaging and Iodine Perfusion Maps Improve Diagnostic Accuracy of Dual-Energy Computed Tomography Pulmonary Angiography With Suboptimal Contrast Attenuation. *Investigative Radiology* [online]. 2017, **52**(11), 659–665. [cit. 2019-05-11]. DOI: 10.1097/RLI.0000000000000387. ISSN 1536-0210. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pubmed/28542094>
- [24] MACBETH, Guillermo, Eugenia RAZUMIEJCZYK a Rubén Daniel LEDESMA. Cliff's Delta Calculator: A non-parametric effect size program for two groups of observations. *Universitas Psychologica* [online]. 2010, **10**(2), 545–555. [cit. 2019-05-13]. DOI: 10.11144/Javeriana.upsy10-2.cdcp. ISSN 1657-9267. Dostupné z URL: https://www.researchgate.net/publication/262763337_Cliff's_Delta_Calculator_A_non-parametric_effect_size_program_for_two_groups_of_observations

- [25] MathWorks. Activecontour. *MathWorks* [online]. ©1994–2018 [cit. 2018-12-23]. Dostupné z URL: <https://www.mathworks.com/help/images/ref/activecontour.html>
- [26] MathWorks. Choosing Between ODBC and JDBC Drivers. *MathWorks* [online]. ©1994–2018 [cit. 2018-12-28]. Dostupné z URL: <https://www.mathworks.com/help/database/ug/choosing-between-odbc-and-jdbc-drivers.html>
- [27] MCCOLLOUGH, Cynthia H. a kol. Dual- and Multi-Energy CT: Principles, Technical Approaches, and Clinical Applications. *Radiology* [online]. 2015, **276**(3), 637–653 [cit. 2018-11-18]. DOI: 10.1148/radiol.2015142631. ISSN 0033-8419. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4557396/>
- [28] NAŇKA, Ondřej a kol. *Přehled anatomie*. Praha: Galén, 2009, 415 s. ISBN 978-80-7262-612-0.
- [29] PELC, Norbert J. Recent and Future Directions in CT Imaging. *Annals of biomedical engineering* [online]. 2014, **42**(2), 260–268. [cit. 2018-11-22]. DOI: 10.1007/s10439-014-0974-z. ISSN 0090-6964. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3958932/>
- [30] PESSIS, Eric a kol. Reduction of Metal Artifact with Dual-Energy CT: Virtual Monospectral Imaging with Fast Kilovoltage Switching and Metal Artifact Reduction Software. *Seminars in Musculoskeletal Radiology* [online]. 2015, **19**(5), 446–455. [cit. 2018-11-30]. DOI: 10.1055/s-0035-1569256. ISSN 1098-898X. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pubmed/26696083>
- [31] RASSOULI, Negin a kol. Detector-based spectral CT with a novel dual-layer technology: principles and applications. *Insights into Imaging* [online]. 2017, **8**(6), 589–598. [cit. 2018-11-20]. DOI: 10.1007/s13244-017-0571-4. ISSN 1869-4101. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5707218/>
- [32] REN, Liqiang, Bin ZHENG a Hong LIU. Tutorial on X-ray photon counting detector characterization. *Journal of X-Ray Science and Technology* [online]. 2018, **26**(1), 1-28 [cit. 2018-11-19]. DOI: 10.3233/XST-16210. ISSN 08953996. Dostupné z URL: https://www.researchgate.net/publication/321139350_Tutorial_on_X-ray_photon_counting_detector_characterization
- [33] RODRIGUEZ-GALIANO, V. F. a kol. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing* [online]. 2012, **67**, 93–104. [cit. 2019-04-23] DOI:

- 10.1016/j.isprsjprs.2011.11.002. ISSN 0924-2716. Dostupné z URL: <https://www.sciencedirect.com/science/article/pii/S0924271611001304>
- [34] SCHLOMKA, J. P. a kol. Experimental feasibility of multi-energy photon-counting K-edge imaging in pre-clinical computed tomography. *Physics in Medicine & Biology* [online]. 2008, **53**(15), 4031. [cit. 2018-11-27]. DOI: 10.1088/0031-9155/53/15/002. ISSN 0031-9155. Dostupné z URL: <http://stacks.iop.org/0031-9155/53/i=15/a=002>
- [35] SHEFER, Efrat a kol. State of the Art of CT Detectors and Sources: A Literature Review. *Current Radiology Reports* [online]. 2013, **1**(1), 76–91. [cit. 2018-11-30]. DOI: 10.1007/s40134-012-0006-4. ISSN 2167-4825. Dostupné z URL: <https://link.springer.com/article/10.1007%2Fs40134-012-0006-4>
- [36] SONKA, Milan, Vaclav HLAVAC a Roger BOYLE. *Image processing, analysis, and machine vision*. 3. ed., internat. student ed. Stamford, Conn.: Cengage Learning, 2008. 829 s. ISBN 978-0-495-24438-7.
- [37] SULLIVAN, Gail M. a Richard FEINN. Using Effect Size—or Why the P Value Is Not Enough. *Journal of Graduate Medical Education* [online]. 2012, **4**(3), 279–282. [cit. 2019-03-12]. DOI: 10.4300/JGME-D-12-00156.1. ISSN 1949-8349. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3444174/>
- [38] WALEK, Petr, Martin LAMOŠ, Jiří JAN. *Analýza biomedicínských obrazů* [online]. 2. aktualizované vydání. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2015. 178 s. [cit. 2018-12-16]. ISBN 978-80-214-4792-9. Dostupné z URL: https://moodle.vutbr.cz/pluginfile.php/202164/mod_resource/content/1/Skripta_ke_cviceni/SkriptaFAB0Aktualizovane.pdf
- [39] WRIGHT, Marvin N. a Inke R. KÖNIG. Splitting on categorical predictors in random forests. *PeerJ* [online]. 2019, **7**. [cit. 2019-04-23]. DOI: 10.7717/peerj.6339. ISSN 2167-8359. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6368971/>
- [40] XIN-YE, Ni a kol. Application of Metal Implant 16-Bit Imaging: New Technique in Radiotherapy. *Technology in Cancer Research & Treatment* [online]. 2017, **16**(2), 188–194. [cit. 2018-11-24]. DOI: 10.1177/1533034616649530. ISSN 1533-0346. Dostupné z URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5616029/>

Seznam symbolů, veličin a zkratek

BMD	Dekompozice na základní materiály („Basis material decomposition“)
CT	Výpočetní tomografie („Computed Tomography“)
DECT	Dvou-energetické CT (v češtině i angličtině též označováno jako Dual-Energy CT)
HU	Hounsfieldova jednotka („Hounsfield Unit“)
kCT	Klasické CT (též „single-energy CT“ či „conventional“ CT); v praktické části práce tato zkratka udává obraz získaný rekonstrukcí dat z DECT, který je analogický tomu získanému z kCT
keV	Kiloelektronvolt – jednotka energie používaná v souvislosti s radiologickým zářením ($1 \text{ eV} = 1,602 \cdot 10^{-19} \text{ J}$)
MDCT	Vícevrstvé detektory („Multiple detector computed tomography“)
MECT	Více-energetické CT (v češtině i angličtině též označováno jako Multi-Energy CT)
RTG	Rentgen
sCT	Spektrální CT („spectral CT“)
VMI	Virtuální monoenergetické/monochromatické obrazy („Virtual Monoenergetic/Monochromatic Images“)


Seznam příloh

A	Klasfikace na základě samotných pixelů	66
A.1	Velký bederní sval / meziobratlová ploténka	66
A.2	Tepenná krev / žilní krev	66
A.3	Mícha / koňský ohon	67
A.4	Játra / ledvina	67
A.5	Kompaktní kost / spongiózní kost	68
B	Obsah přiloženého CD	69

A Klasifikace na základě samotných pixelů


Všechny parametrické obrazy byly v MATLABu vykresleny pomocí funkce *imshow(obr, [])*, která transformuje celý rozsah vstupních hodnot (tj. od minimální do maximální hodnoty parametru) do odstínů šedi (tedy 0–255). Jelikož kostní tkáň 40 keV výrazně utlumí, obsahuje tento obraz vysoké hodnoty CT čísel, a tím pádem se celý obraz jeví jako tmavší. První tkáň z uvedené dvojice je vždy zobrazena modrou barvou, druhá tkáň červenou.

A.1 Velký bederní sval / meziobratlová ploténka




Obr. A.1: Specificita značí úspěšnost klasifikace velkého bederního svalu (modrou barvou), senzitivita meziobratlové ploténky (červenou barvou).

A.2 Tepenná krev / žilní krev



Obr. A.2: Specificita značí úspěšnost klasifikace žilní krve (červenou barvou), senzitivita tepenné krve (modrou barvou). Břišní aorta je vpravo, dolní dutá žíla vlevo.

A.3 Mícha / koňský ohon




(a) kCT
Sp: 34,20 %, Se: 72,99 %

(b) VMI 90 keV
Sp: 45,78 %, Se: 69,23 %

(c) všechny VMI
Sp: 41,08 %, Se: 73,61 %

Obr. A.3: Specificita značí úspěšnost klasifikace koňského ohonu (červenou barvou), senzitivita míchy (modrou barvou).

A.4 Játra / ledvina




(a) kCT
Sp: 72,64 %, Se: 73,76 %

(b) VMI 160 keV
Sp: 86,30 %, Se: 86,68 %

(c) všechny VMI
Sp: 86,98 %, Se: 86,76 %

Obr. A.4: Specificita značí úspěšnost klasifikace ledviny (červenou barvou), senzitivita jater (modrou barvou).

A.5 Kompaktní kost / spongiózní kost



(a) kCT

Sp: 99,55 %, Se: 96,68 %

(b) VMI 100 keV

Sp: 99,63 %, Se: 97,39 %

(c) všechny VMI

Sp: 98,58 %, Se: 94,90 %

Obr. A.5: Specificita značí úspěšnost klasifikace spongiózní kosti (červenou barvou), senzitivita kompaktní kosti (modrou barvou).

B Obsah přiloženého CD

Přiložené CD kromě bakalářské práce v pdf obsahuje databázi nasbíraných dat od 14 pacientů a skripty (vytvořené v MATLABu R2016b) využívané při bakalářské práci. Cílem bakalářské práce však nebylo vytvořit spustitelný program pro uživatele. Tyto skripty byly vytvořeny pouze za účelem sběru dat do bakalářské práce a v přílohách jsou pouze na ukázkou (tj. nejsou spustitelné bez příslušných dat a interakce s uživatelem).

Databáze obsahuje data od 14 pacientů, přičemž bylo nasbíráno 2 925 000 dat. I když datové typy atributů byly nastaveny jako nejmenší možné (např. z typu dlouhé celé číslo pouze na celé číslo), databáze je natolik objemná, že se nevejde do limitu 15 MB elektronických příloh, které se ukládají na internet. Proto je databáze pouze na CD, které je k bakalářské práci přiloženo.

Naopak skripty dosahují několika kB, a proto nebylo problémem je umístit i do internetových elektronických příloh. Jak bylo řečeno výše, skripty nejsou spustitelné a slouží pouze jako ukázková programovací činnost spjatá s bakalářskou prací. Často rovněž nebyly spouštěny celé skripty, ale pouze určité úseky skriptů, které byly zrovna potřeba (např. v Charakterizace_tkani.m byl jednou spuštěn úsek pro Cohenovo d, jednou pro Cliffovo delta, apod.). Označení skriptů napovídá jejich použití v jednotlivých částech bakalářské práce. Chronologicky jdou po sobě následovně:

- 1) Nacteni_pacienta.m
- 2) Segmentace_a_masky.m
- 3) Do_databaze.m
- 4) Charakterizace_tkani.m
- 5) ROC_krivky.m
- 6) Samotne_pixely.m
- 7) Region_pixelu.m
- 8) Kombinovany_pristup.m