



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

**ANALÝZA 3D CT OBRAZOVÝCH DAT SE ZAMĚŘENÍM NA
DETEKCI A KLASIFIKACI SPECIFICKÝCH STRUKTUR
TKÁNÍ**

ANALYSIS OF 3D CT IMAGE DATA AIMED AT DETECTION AND CLASSIFICATION OF SPECIFIC TISSUE
STRUCTURES

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jakub Šalplachta

VEDOUCÍ PRÁCE

SUPERVISOR

prof. Ing. Jiří Jan, CSc.

BRNO 2017

Diplomová práce

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

Ústav biomedicínského inženýrství

Student: Bc. Jakub Šalplachta

ID: 155561

Ročník: 2

Akademický rok: 2016/17

NÁZEV TÉMATU:

Analýza 3D CT obrazových dat se zaměřením na detekci a klasifikaci specifických struktur tkání

POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte metody klasifikace a segmentace tkání v obrazových datech obecně a zaměřte se pak speciálně na CT data. 2) Seznamte se přehledově s koncepty stanovování kostní density z CT dat včetně výběru vhodných typů srovnávacích tkání. 3) Navrhněte koncepci programu pro ověření známých metod segmentace tkání, potřebných pro stanovování kostní density z CT dat, s ohledem na dostupná data a s výhledem na možné modifikace. 4) Implementujte program a proveďte ověřovací výpočty. 5) Zhodnoťte kriticky výsledky jednotlivých metod a popřípadě navrhněte vhodné úpravy metod s cílem dosažení přesnější diagnostiky. 6) Kromě technického posouzení výsledků si podle možností vyžádejte i medicínské zhodnocení.

DOPORUČENÁ LITERATURA:

[1] J. Jan: Medical Image Processing, Reconstruction and Restoration. CRC Press Taylor & Francis, 2006.

[2] G. Schaefer, A.E. Hassanien, J. Jiang: Computational Intelligence in Medical Imaging. CRC Press Taylor & Francis, 2009.

Termín zadání: 6.2.2017

Termín odevzdání: 19.5.2017

Vedoucí práce: prof. Ing. Jiří Jan, CSc.

Konzultant: Petr Ouředníček

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

UPOZORNĚNÍ:

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

Abstrakt

Tato diplomová práce se zabývá segmentací a klasifikací paraspinálního svalu a podkožní tukové tkáně na základě 3D CT obrazových dat, a to za účelem jejich následného využití jako interních kalibračních fantomů pro výpočet minerální hustoty obratle. Vybrané přístupy byly testovány a následně hodnoceny z hlediska správnosti klasifikace a také jejich celkové funkčnosti pro následný výpočet hodnoty BMD. Vlastní testování bylo realizováno v programovacím prostředí Matlab®, a to na vytvořené patientské databázi obsahující lumbální část páteře pro celkově 12 pacientů. Následující sekce této práce obsahují popis problematiky stanovování kostní denzity, segmentačních a klasifikačních metod a popis vlastní realizace.

Klíčová slova

interní kalibrační tkáně, minerální kostní denzita, globální prahování, texturní analýza, k-means shlukování, klasifikace algoritmem náhodného lesa, non-local means

Abstract

This thesis deals with the segmentation and classification of paraspinal muscle and subcutaneous adipose tissue in 3D CT image data in order to use them subsequently as internal calibration phantoms to measure bone mineral density of a vertebrae. Chosen methods were tested and afterwards evaluated in terms of correctness of the classification and total functionality for subsequent BMD value calculation. Algorithms were tested in programming environment Matlab® on created patient database which contains lumbar spines of twelve patients. Following sections of this thesis contain theoretical research of the issue of measuring bone mineral density, segmentation and classification methods and description of practical part of this work.

Key words

internal calibration tissues, bone mineral density, global thresholding, texture analysis, k-means clustering, random forest classification, non-local means

Bibliografická citace:

ŠALPLACHTA, J. Analýza 3D CT obrazových dat se zaměřením na detekci a klasifikaci specifických struktur tkání. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2017. 93 s. Vedoucí diplomové práce prof. Ing. Jiří Jan, CSc..

Prohlášení

Prohlašuji, že svou závěrečnou práci na téma Analýza 3D CT obrazových dat se zaměřením na detekci a klasifikaci specifických struktur tkání jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si 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.

V Brně dne 19. května 2017

.....

podpis autora

Poděkování

Děkuji vedoucímu diplomové práce prof. Ing. Jiřímu Janovi, CSc. a také konzultantovi této práce MUDr. Petru Ouředníčkovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne 19. května 2017

.....
podpis autora

Obsah

Seznam obrázků.....	9
Seznam tabulek.....	11
Úvod	13
1. Metody stanovování kostní denzity	15
1.1 DXA.....	15
1.2 QCT	15
1.3 Stanovování BMD obratlů s využitím CT dat a interních kalibračních tkání.....	16
1.4 Přehled metod využívajících interní kalibrační tkáň při výpočtu BMD těla obratle.....	17
1.4.1 Metoda Boden	17
1.4.2 Metoda Zhao.....	18
1.4.3 Metoda Tay.....	21
2. Metody segmentace obrazu.....	25
2.1 Metody s prostým hodnocením jasu	25
2.1.1 Prahování.....	25
2.1.2 Metoda rozvodí.....	26
2.2 Texturní analýza	27
2.2.1 Statistické metody	28
2.2.2 Strukturní metody.....	31
2.2.3 Metody založené na modelech a transformační metody	32
2.3 Tvarová analýza.....	34
3. Klasifikační metody	35
3.1 Klasifikátory	35
3.1.1 Příznakový klasifikátor.....	36
3.1.2 Příznaky.....	36
3.2 Shluková analýza	37
3.2.1 K-means.....	38

3.2.2	Fuzzy k-means	39
3.3	Klasifikace algoritmem náhodného lesa	40
4.	Publikované postupy pro segmentaci a klasifikaci interních kalibračních tkání na základě CT dat	43
4.1	Publikace – paraspinální sval.....	43
4.2	Publikace – tuková tkáň	44
5.	Statistické metody použité pro redukci vektoru příznaků a redukce šumu metodou NLM.....	47
5.1	Korelační analýza	47
5.2	Analýza hlavních komponent	47
5.3	Diskriminační analýza	48
5.4	Redukce šumu algoritmem Non-Local means.....	49
6.	Vlastní metodologické řešení	51
6.1	Vytvoření databáze patientských dat	51
6.2	Manuální označování interních kalibračních tkání	52
6.3	Testování zvolených segmentačních a klasifikačních přístupů	54
6.3.1	Globální prahování	54
6.3.2	Texturní analýza s klasifikací algoritmem k-means	55
6.3.3	Klasifikace algoritmem náhodného lesa.....	65
6.4	Testování možných modifikací.....	66
6.4.1	Redukce šumu	66
6.4.2	Využití anatomické informace o lokalizaci interních kalibračních tkání.....	68
6.4.3	Využití redukovaného vektoru texturních příznaků pro klasifikaci algoritmem náhodného lesa	69
6.5	Hodnocení dosažených výsledků.....	70
7.	Implementace metodologického řešení.....	71
7.1	Globální prahování	71
7.2	Texturní analýza s klasifikací texturních příznaků algoritmem k-means .	72
7.2.1	Dílní použité funkce	73
7.3	Klasifikace algoritmem náhodného lesa	75

7.4	Filtrace šumu algoritmem NLM	76
7.5	Hodnocení úspěšnosti	76
7.6	Finální implementační řešení.....	78
8.	Diskuze dosažených výsledků.....	79
	Závěr	84
	Použité zdroje	85
	Seznam zkratk.....	93
A.	Přílohy	94

Seznam obrázků

Obrázek 1-1: Vzorové umístění oblastí zájmu, včetně odpovídajících histogramů pro dané oblasti. Levý histogram odpovídá větší oblasti obsahující podkožní tuk (levý pík kolem hodnoty -90 HU) a paraspinální sval (pravý pík kolem hodnoty +40 HU). Druhý graf četností (vpravo) odpovídá oblasti těla obratle. Převzato z: [4].	18
Obrázek 3-1: Obecné schéma klasifikátoru. Převzato z [35].	35
Obrázek 3-2: Schéma obecného příznakového klasifikátoru. Převzato z: [35].	36
Obrázek 3-3: Princip shlukové analýzy a) Iniciační centroidy (barevné kruhy) a vstupní objekty (šedé čtverce); b) Objekty zařazené k iniciačním centroidům; c) Posun centroidů; d) Zařazení objektů k novým centroidům. Převzato z: [38].	39
Obrázek 3-4: Ukázka rozdělení prostoru trénovací množiny (vpravo) na základě příslušného rozhodovacího stromu (vlevo), kdy probíhá dělení do tří klasifikačních tříd. Převzato z: [48].	40
Obrázek 3-5: Princip klasifikace neznámého vektoru x algoritmem náhodného lesa, kdy finální zařazení ke klasifikační třídě y je získáno jako modus zařazení jednotlivých rozhodovacích stromů. Převzato z: [49].	42
Obrázek 6-1: Původní data – řez nativním L2 obratlem daného pacienta.	52
Obrázek 6-2: Vstupní data pro testované metody – výřez z původních dat (řez nativním obratlem L2 daného pacienta).	52
Obrázek 6-3: Vstupní data pro testované metody – výřez z původních dat (řez nativním obratlem L2 daného pacienta).	52
Obrázek 6-4: Překrytí označených dat a vstupních dat pro testované metody – výřez z původních dat (řez nativním obratlem L2 daného pacienta). Legenda: šedá barva – paraspinální sval, bílá barva – podkožní tuk.	52
Obrázek 6-5: Histogram jasových hodnot označené oblasti podkožní tukové tkáně pro daný řez s vyznačeným specifickým intervalem.	53
Obrázek 6-6: Histogram jasových hodnot označené oblasti paraspinálního svalu pro daný řez s vyznačeným specifickým intervalem.	53
Obrázek 6-7: Překrytí zpřesněné masky a odpovídajícího výřezu z tomografického řezu (řez nativním obratlem L2 daného pacienta). Legenda: šedá barva – paraspinální sval, bílá barva – podkožní tuk.	54
Obrázek 6-8: Překrytí zpřesněné masky po dilataci a odpovídajícího výřezu z tomografického řezu (řez nativním obratlem L2 daného pacienta). Legenda: šedá barva – paraspinální sval, bílá barva – podkožní tuk.	54
Obrázek 6-9: Histogram jasových hodnot podkožní tukové tkáně na základě nativních dat s vyznačeným specifickým intervalem.	55

Obrázek 6-10: Histogram jasových hodnot paraspínálního svalu na základě nativních dat s vyznačeným specifickým intervalem.	55
Obrázek 6-11: Biplot korelací prvních dvou hlavních komponent pro vzdálenosti 2 a 4 u matic současného výskytu na základě nativních dat.	58
Obrázek 6-12: Biplot korelací prvních dvou hlavních komponent pro nekorelované 3D texturní příznaky na základě statistických metod I. řádu pro nativní data.	61
Obrázek 6-13: Výstup shlukové analýzy algoritmem k-means (dělení do 5 shluků), kdy vstupem byly všechny příznaky zařazené do výsledného diskriminačního modelu pro odlišení tkání zájmu na základě nativních dat.	63
Obrázek 6-14: Výstup shlukové analýzy algoritmem k-means (dělení do 5 shluků), kdy vstupem byly pouze první dva příznaky s největší diskriminační silou pro tkáň zájmu na základě nativních dat.	63
Obrázek 6-15: Závislost out-of-bag chyby vytvořeného rozhodovacího modelu pro nativní data na počtu rozhodovacích stromů zapojených v klasifikačním procesu.	66
Obrázek 6-16: Výřez z původních nativních vstupních dat (řez L2 obrátem daného pacienta).	68
Obrázek 6-17: Výřez z filtrovaných nativních dat (řez L2 obrátem daného pacienta).	68
Obrázek 6-18: Původní výřez z nativních vstupních dat (řez L2 obrátem daného pacienta).	69
Obrázek 6-19: Výřez z nativních vstupních dat s využitím anatomické informace o lokalizaci interních kalibračních tkání (řez L2 obrátem daného pacienta).	69
Obrázek 7-1: Blokové schéma finální funkce. Vstupy (a), probíhající činnosti (b) a výstup (c).	78
Obrázek 8-1: Výsledky testovaných metod pro zvolený řez (nativní L2 obrátem): a) Manuálně označená data (zlatý standard); b) Globální prahování; c) Texturní analýza + algoritmus k-means; d) Náhodný les. Legenda: šedá barva – paraspínální sval, bílá barva – podkožní tuk.	79
Obrázek 8-2: Grafické znázornění odchylek stanovených hodnot BMD, pro dané řezy těly nativních obrátlů, s využitím klasifikačních výstupů jednotlivých testovaných metod vůči referenčním hodnotám stanovených s využitím databáze manuálně označených dat.	83

Seznam tabulek

Tabulka 6-1: Přehled stanovených specifických jasových intervalů použitých v rámci globálního prahování interních kalibračních tkání.	55
Tabulka 6-2: Přehled počtů texturních příznaků počítaných na základě jednotlivých metod texturní analýzy.....	56
Tabulka 6-3: Pearsonovy korelační koeficienty vzdáleností u matic současného výskytu.....	57
Tabulka 6-4: Pearsonovy korelační koeficienty směrů u matic délky běhů.	58
Tabulka 6-5: Nalezené optimální nastavení pro matice současného výskytu a matice délky běhů.	59
Tabulka 6-6: Pearsonovy korelační koeficienty 3D texturních příznaků na základě statistických metod prvního řádu (nativní data).	61
Tabulka 6-7: Přehled neredundantních 3D texturních příznaků z jednotlivých sekcí texturní analýzy pro nativní i kontrastní data.	62
Tabulka 6-8: Parametry diskriminačního modelu obsahujícího pouze první dva příznaky s největší diskriminační silou pro tkáň zájmu na základě nativních dat.	63
Tabulka 6-9: Parametry výsledného diskriminačního modelu pro odlišení tkání zájmu na základě nativních dat.	63
Tabulka 6-10: Přehled stanovených charakteristik interních kalibračních tkání (modus, medián, průměr, směrodatná odchylka).....	64
Tabulka 8-1: Výsledky testovaných přístupů na testovací databázi nativních dat. .	80
Tabulka 8-2: Přínos využití anatomické informace o lokalizaci interních kalibračních v kombinaci s redukcí šumu ve vstupních datech pro výsledky testovaných přístupů na databázi nativních dat.	81
Tabulka 8-3: Výsledky testovaných přístupů s využitím anatomické informace o lokalizaci interních kalibračních tkání v kombinaci s redukcí šumu na databázi nativních dat.....	82
Tabulka A-1: Seznam počítaných 3D texturních příznaků (198 pro příznaků pro voxel).	94
Tabulka A-2: Přehled stanovených specifických jasových intervalů použitých v rámci globálního prahování interních kalibračních tkání na základě filtrovaných dat.	95
Tabulka A-3: Nalezené optimální nastavení pro výpočet matic současného výskytu a matic délky běhů na základě filtrovaných dat.	95
Tabulka A-4: Přehled neredundantních 3D texturních příznaků z jednotlivých sekcí texturní analýzy pro filtrovaná nativní i kontrastní data.	95
Tabulka A-5: Přehled stanovených charakteristik interních kalibračních tkání pro filtrovaná data (modus, medián, průměr, směrodatná odchylka).	96

Tabulka A-6: Výsledky testovaných přístupů na testovací databázi kontrastních dat.	96
Tabulka A-7: Výsledky testovaných přístupů s využitím redukce šumu ve vstupních datech na databázi nativních dat.	96
Tabulka A-8: Přínos redukce šumu ve vstupních datech pro výsledky testovaných přístupů na databázi nativních dat.	97
Tabulka A-9: Výsledky testovaných přístupů s využitím redukce šumu ve vstupních datech na databázi kontrastních dat.	97
Tabulka A-10: Přínos redukce šumu ve vstupních datech pro výsledky testovaných přístupů na databázi kontrastních dat.	98
Tabulka A-11: Výsledky testovaných přístupů s využitím anatomické informace o lokalizaci interních kalibračních tkání na databázi nativních dat.	98
Tabulka A-12: Přínos využití anatomické informace o lokalizaci interních kalibračních tkání pro výsledky testovaných přístupů na databázi nativních dat.	99
Tabulka A-13: Výsledky testovaných přístupů s využitím anatomické informace o lokalizaci interních kalibračních tkání na databázi kontrastních dat.	99
Tabulka A-14: Přínos využití anatomické informace o lokalizaci interních kalibračních tkání pro výsledky testovaných přístupů na databázi kontrastních dat. ...	100
Tabulka A-15: Výsledky testovaných přístupů s využitím anatomické informace o lokalizaci interních kalibračních tkání v kombinaci s redukcí šumu na databázi kontrastních dat.	100
Tabulka A-16: Přínos využití anatomické informace o lokalizaci interních kalibračních v kombinaci s redukcí šumu ve vstupních datech pro výsledky testovaných přístupů na databázi kontrastních dat.	101
Tabulka A-17: Přínos využití neredundantního vektoru texturních příznaků pro klasifikaci algoritmem náhodného lesa na testovací databázi nativních dat.	101
Tabulka A-18: Přínos využití neredundantního vektoru texturních příznaků pro klasifikaci algoritmem náhodného lesa na testovací databázi kontrastních dat.	102

Úvod

Minerální denzita kostí je definována jako množství kostních minerálů v rámci určitého objemu dané kosti, přičemž nejčastěji je hodnocena plošná a objemová hodnota BMD (z anglického „Bone Mineral Density“) [1]. Hodnota minerální denzity je v praxi diagnosticky využívána v souvislosti s onemocněním kostního aparátu osteoporózou. Toto onemocnění v současné době patří mezi populační choroby mezi staršími jedinci, a zvláště pak post-menopauzickými ženami [2], přičemž se jedná o onemocnění skeletu charakteristické sníženou kostní masou a rozpadem mikroarchitektury kostní tkáně, což může vyústit ve fraktury z důvodu křehkosti [3]. Zvláště nebezpečná je situace, kdy toto řídnutí postihne páteř, což může vést až ke zborcení jednotlivých obratlů. Pro funkční léčbu tohoto závažného onemocnění je proto klíčové včasné odhalení.

V současnosti jsou za zlatý standard pro diagnostiku osteoporózy považovány vyšetření DXA (z anglického „Dual-energy X-ray Absorptiometry“) a QCT (z anglického „Quantitative Computed Tomography“). Tyto metody slouží k určení minerální denzity, která je v tomto případě využívána jako přímý diagnostický prostředek. Jedná se však o vysoce specializovaná vyšetření, jež jsou prováděna až po projevení prvních příznaků. Nutnost včasného odhalení osteoporózy proto vedla ke vzniku metod umožňujících výpočet BMD na základě jakýchkoliv CT dat, pořízených primárně pro jiné účely. [4] [5] [6]

Tyto metody využívají pro vlastní výpočet minerální denzity interní kalibrační tkáně, kterými konkrétně mohou být paraspinální sval a tuková tkáň. U těchto kalibračních tkání je výhodná jejich lokalizace v okolí vlastního těla obratle, tudíž přesněji odrazí lokální změny rentgenového svazku jím procházejícím oproti externě umístěným kalibračním fantomům [4]. Při vhodné automatizaci celého postupu výpočtu BMD na základě CT obrazových dat s využitím interních kalibračních tkání by tato metodika mohla sloužit pro screeningovou diagnostiku osteoporózy, kdy vlastní výpočet by bylo možné provádět na jakékoliv CT stanici na pozadí rutinních vyšetření. Pro zmíněnou automatizaci je však klíčová klasifikace a následná segmentace interních kalibračních tkání.

Pro řešení dané úlohy byly testovány tři zvolené segmentační a klasifikační přístupy, jež byly vybrány s ohledem na publikované postupy zabývající se danou problematikou a také na celý charakter dané úlohy a vstupních dat. Konkrétně byly testovány globální prahování, texturní analýza s klasifikací texturních příznaků algoritmem k-means a klasifikace algoritmem náhodného lesa. Vlastní testování proběhlo na vytvořené databázi patientských dat, jež obsahovala tomografická data lumbálních páteří pro celkově 12

pacientů. Konkrétně se jednalo o data s vysokým rozlišením, jež byla nasnímana na CT systému Philips. Na této databázi proběhlo také manuální označování tkání zájmu, čímž byl vytvořen zlatý standard pro následné statistické hodnocení, ale vznikla tím také učební množina, jež byla využita v rámci realizace všech testovaných přístupů. Pro hodnocení úspěšnosti vlastní klasifikace interních kalibračních tkání jednotlivými testovanými přístupy bylo provedeno statistické vyhodnocení dosažených výsledků, ale byla také hodnocena funkčnost jednotlivých přístupů z hlediska následného výpočtu minerální denzity obratlů. Vyžádáno bylo také lékařské zhodnocení. Celkově nejlepší funkčnosti dosáhla klasifikace algoritmem náhodného lesa. Oproti tomu nejhorších výsledků dosáhla texturní analýza s klasifikací texturních příznaků algoritmem k-means, což svědčí o nízkém významu texturní informace pro řešení dané úlohy.

1. Metody stanovování kostní denzity

1.1 DXA

Technika nazývaná DXA (z anglického „Dual-energy X-ray Absorptiometry“) využívá pro určení minerální denzity kostní tkáně dva rentgenové snímky, a to získané při dvou různých anodových napětích (odtud pochází i její název), v praxi využívaná napětí jsou například 80 kV a 120 kV [7]. Snímáním při různých anodových napětích dojde k výrazné eliminaci artefaktu utvrzování svazku, což je pro vlastní výpočet BMD velmi výhodné. Na základě metody DXA je však možné získat pouze hodnotu plošné minerální denzity [mg/cm^2] [8], ta však může být zkreslena vlivem okolních tělesných struktur. Z tohoto důvodu je tato metoda nepoužitelná pro určování minerální denzity hrudních a krčních obratlů, kdy tyto struktury jsou skryty lebkou či hrudním košem [9]. Dalšími zkreslujícími vlivy pro výpočet BMD s využitím techniky DXA mohou být kalcifikace v okolí kostních tkání, či zvýšený BMI index (z anglického „Body Mass Index“) u daného pacienta [9]. Další nevýhoda vychází z principu této techniky, kdy nutnost dvou snímků s sebou přináší vyšší dávku ionizujícího záření absorbovanou tělem pacienta [7]. I přes tyto zmíněné nevýhody je tato technika považována Světovou zdravotnickou organizací (WHO) jako zlatý standard pro diagnostiku osteoporózy a data získaná touto technikou jsou dále využívána jako vstup do algoritmů pro vyhodnocování riziku fraktur [3] [10].

1.2 QCT

Na rozdíl od DXA je na základě měření QCT (z anglického „Quantitative Computed Tomography“) možné získat hodnotu objemového BMD [mg/cm^3] [8]. Touto technikou je možné přesně určit hodnotu minerální hustoty obratle i v případech, kdy se u daného pacienta vyskytují mimo-kostní kalcifikace, osteofyty či degenerativní fenomény, což u planárních metod jako například DXA může mít spolu s velikostí pacienta zkreslující tendence [10]. Další výhodou kvantitativní tomografie je fakt, že s jejím využitím je možné získat hodnoty BMD pro kortikální a trabekulární část obratle zvlášť. Celkově je tato technika přesnějším zdrojem hodnot minerální denzity v porovnání s technikou DXA. [10]

V praxi měření minerální hustoty kostí metodou QCT probíhá jako normální CT vyšetření, akorát spolu s pacientem je snímán i kalibrační fantom. Ten slouží ke kalibraci naměřených CT hodnot a odvození BMD požadované tkáně. Kalibrací je zajištěno

potlačení vlivu variability z důvodu snímání na různých stanicích z hlediska výrobce i parametrů. Fantomy bývají složené z částí o známé hodnotě CT čísla a BMD pro dané akviziční parametry. Jednotlivé sekce fantomu mohou například obsahovat vodu, etanol, či K_2HPO_4 o různých koncentracích. Pomocí známých numerických hodnot fantomu jsou naměřené CT hodnoty zkalibrovány a následně je, pomocí známých hodnot minerální hustoty, s využitím lineární regrese odvozena hustota požadované tkáně. Tím je tedy možné získat hodnotu BMD nezávislou na akvizičních parametrech. [4]

Ta však může být zkreslena. Umístěním kalibračního fantomu mimo tělo pacienta může dojít ke vzniku artefaktů, tedy k odchylce od přesné hodnoty např.: z důvodu utvrzování svazku, rozptylu RTG záření či objemovému průměrování [4] [10]. Navíc, fantom lokalizovaný mimo tělo pacienta bude osvětlen spektrem ovlivněným průchodem tělem pacienta. Toto spektrum je přímo závislé na tělesné konstituci a geometrické pozici pacienta v průběhu snímání [3] [4]. Z těchto všech důvodů dochází k degradaci naměřených CT hodnot a tím i následné přesnosti výpočtu BMD. Možných řešení by tedy mohla být lokalizace kalibračního fantomu, co nejbližší vyšetřované oblasti. Toho však v praxi může být těžko dosaženo. [4] [10]

1.3 Stanovování BMD obratlů s využitím CT dat a interních kalibračních tkání

Možným řešením výše zmíněných problémů může být využití interních tkání jako reference. Tyto tkáně, z důvodu blízkosti k oblasti zájmu (tj. obratel), přesněji odrážejí lokální změny rentgenového svazku [4]. Jako interní fantomy jsou v praxi konkrétně využívány paraspinální sval a tuková tkáň. U těchto tkání je předpoklad, že u nich nedochází k velké variabilitě mezi pacienty, tudíž je možné odvodit jejich přesné hodnoty v Hounsfieldových jednotkách pro dané snímací parametry a ty následně použít pro určení denzity tkáně zájmu. [4]

Další výhodou využití interních kalibračních tkání pro určení minerální denzity obratlů, za předpokladu vhodné automatizace celého výpočtu, je možnost analýzu provádět na běžné CT stanici paralelně s jiným probíhajícím vyšetřením. Tento postup se tedy zdá být vhodný pro screeningovou diagnostiku osteoporózy na pozadí rutinních vyšetření s využitím dostupných CT dat, bez nutnosti vystavení pacienta dalšímu rentgenovému záření. Nevýhodou těchto metod může být nerovnoměrná distribuce CT hodnot v rámci tkání zájmu, což může zkreslit výsledné hodnoty [10]. Další faktory negativně ovlivňující přesnost a správnost mohou vznikat na základě stupně hydratace daného pacienta, s čímž úzce souvisí CT čísla svalstva [10]. Funkčnost metod pro určení


BMD s využitím zmíněných interních referenčních tkání je již v praxi testována a dosažené výsledky ukazují vysokou míru korelace mezi metodami v praxi běžně používanými a považovanými jako zlatý standard pro diagnostiku osteoporózy (DXA, QCT), viz studie: [5], [6], [10].

1.4 Přehled metod využívajících interní kalibrační tkáň při výpočtu BMD těla obratle

Do současné doby byly publikované tři metody, které pro výpočet minerální denzity obratlů využívají CT data a vnitřní kalibrační tkáň. Autoři těchto metod se mezi sebou majoritně rozcházejí použitými segmentačními přístupy a dalšími dílčími kroky ve výpočtu BMD. Jednotlivé přístupy a jejich funkčnost jsou popsány v následujících sekcích této práce.

1.4.1 Metoda Boden

První publikace s ideou využití interních kalibračních fantomů v rámci QCT vyšetření pochází z roku 1989. Autoři přišli se semi-automatickým postupem pro určení BMD obratlů na základě CT dat. V prvním kroku je vybrána velká oblast zájmu umístěná posteriorně k tělu lumbálního obratle, kde se nachází referenční tkáň. Klasifikace těchto tkání je provedena na základě analýzy histogramu z této oblasti. Ve vytvořeném grafu četností by měly být patrné dva izolované píky, které odpovídají právě tuku a paraspinálnímu svalu (viz Obrázek 1-1: vlevo dole). Ty jsou následně identifikovány na základě metody hledání gradientu a algoritmu proložení nejmenších čtverců. CT čísla tkání zájmu jsou autory následně definována jako střední hodnota nejlepšího proložení vrcholu histogramu normálním rozložením. Autoři berou tedy v potaz nejčastější hodnotu (modus) raději než průměrnou hodnotu, a to kvůli eliminaci zkreslujících vlivů okolních tkání. V druhém kroku je oblast zájmu je umístěna tak, aby ohraničovala tělo obratle. V rámci histogramu této oblasti je patrný jeden izolovaný, široký pík, odpovídající trabekulární kosti a kostní dřeni (viz Obrázek 1-1: vpravo dole). V posledním kroku jsou určená CT čísla tkání zájmu použita v rámci vlastního výpočtu BMD. Za předpokladu, že tuková a svalová tkáň mají známou hodnotu minerální denzity, která není významně zatížena mezipacientskou variabilitou a že tato hodnota je v rámci pacienta přímo úměrná CT číslům, můžeme získat hodnotu BMD těla obratle pomocí jednoduché extrapolace. [4]



Obrázek 1-1: Vzorové umístění oblastí zájmu, včetně odpovídajících histogramů pro dané oblasti. Levý histogram odpovídá větší oblasti obsahující podkožní tuk (levý pík kolem hodnoty - 90 HU) a paraspinální sval (pravý pík kolem hodnoty +40 HU). Druhý graf četností (vpravo) odpovídá oblasti těla obratle. Převzato z: [4].

Funkčnost metody byla autory testována na 48 zdravých pacientech a srovnána s hodnotami minerální denzity určenými s využitím externího kalibračního fantomu. Dosažené výsledky ukazují, že hodnoty BMD určené na základě interních kalibračních tkání byly nižší. Celkově však tato metoda dosáhla korelace $r=0.96$ s technikou v praxi považovanou jako zlatý standard. [4]

Tato metoda byla v pozměněné formě patentována firmou Philips a implementována do CT stanic této firmy. Hlavním rozdílem oproti původní metodě je nutnost označení tří oblastí, a to pro každou tkáň zájmu zvlášť (podkožní tuková tkáň, paraspinální sval a trabekulární část obratle). Funkčnost této metody byla zkoumána v lékařské studii z roku 2010, do níž bylo zahrnuto 82 pacientů, z toho 61 žen a 21 mužů, přičemž průměrný věk účastníků byl 63 let. Testováno bylo celkově 197 obratlů a dosažená korelace takto určených hodnot BMD s hodnotami určenými na základě klasického QCT vyšetření s využitím externího fantomu byla $r = 0.97$. [10]

1.4.2 Metoda Zhao

Další metoda zabývající se určením minerální denzity obratlů na základě QCT bez využití externího retenčního fantomu pochází z roku 2009. Autoři přišli se semi-automatickým postupem pro segmentaci interních referenčních tkání a těla obratle a následného výpočtu BMD těla obratle. Provedená segmentace je založená na hybridní

metodě růstu oblastí z manuálně zadaného semínka, která využívá lokálně adaptivní práh a morfologické operace. Z takto vysegmentovaných tkání zájmu jsou následně určeny jejich průměrné hodnoty, které jsou používány v dalších krocích metody. Vlastní segmentaci tkání zájmu je možné rozdělit na dvě dílčí části, na segmentaci trabekulární části obratle a segmentaci kalibračních tkání. [8]

Postup segmentace vnitřní části obratle se skládá z několika dílčích kroků. Prvním krokem tohoto procesu je nalezení oblasti ve vstupních datech s nejvyšším průměrným CT číslem, jež je vstupem pro další krok analýzy. V rámci nějž je v této oblasti nalezen bod s nejvyšším CT číslem, který je následně použit jako výchozí bod pro metodu růstu oblastí. Takto vysegmentovaná oblast je ošetřena morfologickými operacemi. Poté je zjištěn maximální poloměr kruhu, který je možné umístit do segmentované oblasti. Střed tohoto kruhu je brán jako střed těla obratle. V rámci vysegmentované oblasti zůstane díra, která odpovídá spinálnímu kanálu. Po nalezení středu této díry, je jím vedena pomyslná přímka kolmá na spojnici středu těla obratle a středu spinálního kanálu, která rozdělí obratel na vlastní tělo a výběžky. V posledním kroku je vysegmentována vlastní trabekulární část obratle. Tak že jsou vybrány body na kontuře, která byla získána segmentací v předchozích krocích. Spojnice těchto bodů tvoří vnější hranici kortikální části obratle, tato ohraničující linie je následně smršťována až do pozice, kdy dojde k relativnímu zvýšení gradientu. Tak je získána vnitřní hranice kortiky obratle, tudíž je vymezena trabekulární oblast těla obratle. [8]

Segmentace kalibračních tkání je autory řešena semi-automaticky. Nejprve je segmentována přibližná oblast levé části sakrospinálního svalu a oblast okolního podkožního tuku, ty jsou následně podrobeny analýze distribuce CT čísel. V prvním kroku je segmentována oblast sakrospinálního svalu. Nejprve je vybrán referenční bod P_{ms} pro vlastní segmentaci, lokalizovaný uprostřed levé části daného svalu, kolem nějž je vytvořena oblast D_{ms} . Distribuční funkce stupňů šedi této oblasti je následně dosazena do rovnice (1-1) [8], která definuje normální rozložení. Z této rovnice jsou vyjádřeny parametry B , E , G a směrodatná odchylka σ tohoto rozložení. Vlastní segmentace je založena na metodě růstu oblastí, přičemž výchozím bodem je bod P_{ms} a interval hodnot oblasti zájmu je definován pomocí určené směrodatné odchylky jako $(-2\sigma, +2\sigma)$. Takto získaná oblast je následně ještě podrobena morfologickým operacím za účelem získání finální oblasti sakrospinálního svalu. Obdobným způsobem je vysegmentována i oblast podkožního tuku. CT hodnoty v takto získaných oblastí zájmu jsou následně podrobeny statistické analýze. Pro každou oblast je vytvořen histogram, který je následně proložen normálním rozložením a střední hodnota tohoto rozložení je charakteristickou hodnotou pro danou tkáň, použitou v dalších krocích. [8]

$$f(h) = Be^{-\left(\frac{h-E}{G}\right)^2} \quad (1-1)$$

Základním principem výpočtu BMD na základě této metody je kalibrace dat s využitím CT čísel tuku a svalů. Autoři vycházejí z teorie, že existuje lineární vztah (viz rovnice (1-3) [8], kde k je sklon a b posun kalibrační křivky) mezi přesnou CT hodnotou H a naměřenou CT hodnotou H' (definována rovnicí (1-2) [6]), kde K je škálovací konstanta, v praxi rovna 1000, μ je lineární koeficient útlumu tkáně zájmu a μ_w je lineární koeficient útlumu vody). Rozdíl CT čísel dvou tkání (v našem případě tuku a svalů, jejichž rozdíl autoři považují za konstantní) vyjádřený rovnicí (1-4) [8] lze poté použít pro vyjádření sklonu k (viz rovnice (1-5) [8], kde H_m je CT číslo svalů, H_f je CT číslo tuku, μ_m je lineární koeficient útlumu svalů, μ_f je lineární koeficient útlumu tuku). Dále existuje předpoklad, že CT číslo vody by mělo být rovné 0 v rámci širokého rozsahu akvizičních parametrů, což je hodnotově mezi CT číslem tuku a CT číslem svalů. Toho lze využít právě pro odvození parametru b , který vyjadřuje odhad kalibrace naměřené CT hodnoty vody do hodnoty 0 (viz rovnice (1-6) [8] a (1-7) [8]). [8]

$$H' = K \cdot \left(\frac{\mu - \mu_w}{\mu_w} \right) \quad (1-2)$$

$$H = k \cdot H' + b \quad (1-3)$$

$$H_m - H_f = k \cdot \left(\frac{\mu_m - \mu_f}{\mu_w} \right) \quad (1-4)$$

$$k = \frac{(H_m - H_f) \cdot \mu_w}{(\mu_m - \mu_f)} \quad (1-5)$$

$$\frac{(H_w - H_f)}{(H_m - H_f)} = \frac{(\mu_w - \mu_f)}{(\mu_m - \mu_f)} \quad (1-6)$$

$$b = \frac{(\mu_w - \mu_f)}{(\mu_m - \mu_f)} \cdot (H_m - H_f) + H_f \quad (1-7)$$

Tímto způsobem zkalibrovanou průměrnou hodnotu CT čísla pro tělo obratle lze následně použít pro určení minerální denzity. Dle autorů lze tento přepočít odvodit z rovnice (1-8) [8], kde H_b je průměrné CT číslo těla obratle, $\mu_{\text{mineral}}/\rho_{\text{mineral}}$ a μ_w/ρ_w jsou koeficienty útlumu hmoty a hustoty a c_{mineral} odpovídá minerální denzitě. Úpravou této rovnice lze tedy získat vztah pro výpočet BMD těla obratle (viz rovnice (1-9)). [8]

$$H_b \approx \frac{(\mu_{mineral}/\rho_{mineral})}{(\mu_w/\rho_w)} \cdot c_{mineral} \quad (1-8)$$

$$c_{mineral} = \frac{(\mu_{mineral}/\rho_{mineral})}{(\mu_w/\rho_w)} \cdot H_b \quad (1-9)$$

Metoda byla autory testována na 94 klinických případech a srovnávána se standartním QCT měřením s využitím externího kalibračního fantomu. Přičemž mezi těmito dvěma postupy bylo dosaženo korelačního koeficientu $r=0.97$. Hodnoty BMD získané pomocí vnitřních kalibračních tkání byly však významně nadhodnoceny oproti přesným hodnotám. Autoři tedy odvodili s využitím lineární regrese a známých hodnot BMD získaných pomocí měření s externím fantomem vztah (rovnice (1-10) [8]), který slouží ke kalibraci vypočtených hodnot. [8]

$$C_{mineral (1)} = 1.034 \cdot C_{mineral (2)} - 14.39 \quad (1-10)$$

Sami autoři však uznávají, že jejich postup není vhodný pro pacienty, jejichž CT čísla svalu a tuku jsou významně odlišná od populačních průměrů [8]. Dalším problémem této metody je, že poměrové členy vystupující v rovnicích (1-4) a (1-7) jsou konstantní pouze v určitém rozmezí akvizčních parametrů. Předpoklad konstantnosti je splněn pouze pro hodnoty napětí 120-140 kV a hodnoty efektivních energií 70-80 keV, přičemž i v tomto intervalu dochází ke kolísání $\pm 2 \%$ [6].

1.4.3 Metoda Tay

Poslední metodou využívající interní kalibrační tkáň pro výpočet minerální denzity obratlů na základě diagnostických CT dat je metoda z roku 2012. Ta je principiálně podobná předchozímu popisovanému postupu. Nejprve dojde k segmentaci těla obratle a následně referenčních tkání, s jejichž využitím dojde ke kalibraci CT hodnot obratle. Následně je proveden odhad plošné minerální denzity. Ta je následně ještě přepočtena tak, aby byla přímo srovnatelná s hodnotou zjištěnou na základě DXA, která má dle autorů vyšší diagnostickou výtěžnost. Před vlastním výpočtem hodnoty BMD jsou však provedeny tři dílčí kroky, z nichž dva jsou segmentační, a jedním je korekce CT čísel. [3]

V rámci první segmentace je lokalizována přibližná pozice obratle a je provedena metoda řezu grafem za účelem získání oblasti celého obratle. Druhou segmentací je obratel rozdělen na vlastní tělo a výběžky. Vlastní lokalizace centroidu obratle je provedena s využitím techniky iterativního hledání. Nejprve provedeno jednoduché prahování s fixním prahem ($HU > 400$), čímž jsou získány prvotní vysegmentované oblasti kostí. Následně je centroid těchto oblastí využit jako výchozí bod pro detekci středu

obratle. Kolem tohoto počátečního středu je vytvořeno okno o velikosti dvojnásobku velikosti průměrného obratle. V dané pozici okna je v ohraničené oblasti kosti nalezen nový centroid a okno se posune tak, aby bylo centrováno kolem tohoto nového středu. To se iterativně opakuje až do doby, kdy se nová pozice centroidu neliší od předchozí nalezené pozice. Prahování použité pro prvotní segmentaci kostí není dostatečně přesné pro rozlišení kostních tkání, proto autoři následně využívají segmentační techniku řezu grafem. V oblasti vymezené oknem centrovaným kolem nalezeného centroidu dojde následně k přesné segmentaci vlastního obratle. [3]

V druhém segmentačním kroku dojde z takto vysegmentovaného obratle k odstranění páteřních výběžků, ty totiž nejsou relevantní pro další analýzu. Segmentace pouze vlastního těla obratle je důležitým krokem, a proto pro zajištění opakovatelnosti a přesnosti toho procesu autoři využívají spinální kanál jako anatomický landmark, jež je možné detekovat s vysokou přesností. Středem tohoto kanálu je následně vedena pomyslná spojnice s centroidem obratle a přímkou kolmou na tuto spojnici a procházející středem kanálu je následně obratel rozdělen na dvě části, čímž dojde k oddělení těla obratle a jeho výběžků. [3]

Dle autorů se CT čísla v rámci dat mohou lišit v závislosti na použitých akvizičních parametrech snímání dat, je tedy podle nich nutné provést korekci, aby byla zachována diagnostická přesnost další analýzy. Autoři k této kalibraci používají pouze paraspinální sval, který podle nich má ideální charakteristiku v rámci CT čísel, která se významně neliší mezi pacienty. Usuzují, že rozdíl mezi reálnou CT hodnotou a ideální CT hodnotou je způsoben právě vlivy akvizičních parametrů a dalších fyzikálních principů. Segmentace vlastního paraspinálního svalu probíhá s využitím spinálních výběžků vysegmentovaných v předchozím kroku. Kolem nichž je vytvořeno okno zahrnující měkké tkáně v okolí výběžků. Tyto tkáně zahrnují právě sval a tuk, přičemž oba typy tkání mají nezávislou Gaussovskou distribuci z hlediska CT čísel. Je vytvořen model obsahující voxely, které neodpovídají vzduchu ani kosti, u nichž se tedy dá usuzovat, že odpovídají měkkým tkáním. Následně je vytvořen histogram tohoto modelu a jsou jím proloženy dvě normální rozložení, z nichž každé odpovídá pouze jedné z daných tkání. [3]

Následně je určena průměrná hodnota svalové tkáně, která je použita pro korekci. Ta je relativně jednoduchá a popsána vztahem (1-11) [3], kde HU_{muscle} je průměrná CT hodnota svalu v rámci reálných dat a hodnota 40 je tabulková hodnota pro paraspinální sval. Na základě této rovnice získaná hodnota HU_{offset} je následně přičtena ke všem voxelům v těle obratle, čímž je provedena kalibrace. [3]

$$HU_{offset} = 40 - HU_{muscle} \quad (1-11)$$

Takto zkalibrované hodnoty již mohou být použity pro vlastní výpočet minerální denzity. Autoři vycházejí ze studie [11], jejíž autoři odvodili vztah mezi CT číslem voxelu a BMD (ρ), tento vztah je vyjádřen rovnicí (1-13) [3]. Tato hodnota je následně použita pro výpočet minerálního obsahu kostní tkáně (BMC_{CT} z anglického „Bone Mineral Content“), viz rovnice (1-13) [3], kde S_y vzdálenost mezi jednotlivými řezy a S_x je velikost hrany voxelu. Pro určení minerální denzity vlastního obratle je však ještě nutné provést výpočet plochy daného obratle (A_{bone}), viz rovnice (1-14) [3], kde A_{pixel} je počet pixelů v rámci jedné projekce a proměnné S_y , S_x mají stejný význam jako v předchozím vztahu (rovnice (1-13)). Vlastní výpočet BMD těla obratle ($aBMD_{CT}$) je vyjádřen rovnicí (1-15) [3]. [3]

$$\rho = 1.112 \cdot HU + 47 \text{ kg/m}^3 \quad (1-12)$$

$$BMC_{CT} = \sum \rho \cdot S_y \cdot S_x^2 \quad (1-13)$$

$$A_{bone} = A_{pixel} \cdot S_y \cdot S_x \quad (1-14)$$

$$aBMD_{CT} = \frac{BMC_{CT}}{A_{bone}} \quad (1-15)$$

Takto vypočtená hodnota $aBMD_{CT}$ může být dle autorů použita k odhadu $aBMD_{DXA}$ (minerální denzita určená metodou DXA). Tyto dvě hodnoty nemohou být však přímo zaměňovány, a to z důvodu určení minerální denzity na základě různých radiologických metod. Autoři usuzují, že mezi hodnotou $aBMD_{CT}$ a $aBMD_{DXA}$ existuje lineární vztah vyjádřený vztahem (1-16) [3]. [3]

$$aBMD_{CT} = k_1 \cdot aBMD_{DXA} + k_2 \quad (1-16)$$

Neznáme konstanty k_1 a k_2 byly autory určeny na základě metody RANSAC, a to z důvodu eliminace odlehlých hodnot, které by měly zkreslující vliv na danou transformační funkci. Výsledný vztah má tedy podobu [3]:

$$aBMD_{DXA} = 0.866 \cdot aBMD_{CT} + 0.194 \text{ g/cm}^2. \quad (1-17)$$

Tato metoda byla autory testována na souboru 44 mužských pacientů, kteří měli průměrný věk 66,7 let. Výsledná hodnota $aBMD_{DXA}$ byla přímo porovnáována s hodnotou minerální denzity získanou přímo měřením DXA a bylo dosaženo korelace $r=0.85$ (při odstranění odlehlých hodnot metodou RANSAC byla hodnota korelace $R=0.88$). [3]

Předpoklad autorů, že hodnota CT čísla paraspinálního svalu je mezi pacienty konstantní, byl vyvrácen studií z roku 2012 [12]. V níž bylo prokázáno, že pouhý věk dokáže tuto hodnotu odchýlit až o 15 HU. Dále v ní bylo ukázáno, že dalšími významnými vlivy na CT hodnotu jsou hydratace organismu či stupeň atrofie. Na základě těchto faktů se dá usuzovat, že autory použitá metoda kalibrace je v praxi nepoužitelná.

2. Metody segmentace obrazu

Segmentace obrazu náleží do třídy analýzy obrazu, jejímž cílem je popis a charakteristika daných obrazových dat spíše než jejich úprava. Segmentaci obrazu je možné definovat jako rozdělení vstupních dat na nepřekrývající se oblasti (segmenty), které odpovídají strukturám obrazu [13]. Vzniklé segmenty jsou vůči sobě disjunktní (nemají žádný společný prvek) a plně zaplňují oblast vstupního obrazu. Dále platí, že jednotlivé segmenty jsou homogenní vůči zvolenému parametru (příznaku – v nejjednodušším případě jasová hodnota), jímž jsou charakterizovány. Vlastní segmentační algoritmy je možné rozdělit do několika kategorií: segmentace podle homogenity oblastí (např. prahování), regionově orientované segmentace (např. metoda dělení a slučování oblastí, metoda narůstání oblastí), hranově orientované techniky (Houghova transformace) a hybridní techniky [14]. V praxi neexistuje jednotný segmentační přístup a vlastní postup je plně závislý na konkrétní úloze. Vybrané segmentační techniky budou dále popsány v následujících sekcích této práce. [13] [14]

2.1 Metody s prostým hodnocením jasu

2.1.1 Prahování

Prahování patří z hlediska principu mezi nejjednodušší segmentační techniky, kdy je využita pouze intenzitní informace [13]. V rámci tohoto postupu je pro každou třídu (výsledný segment) stanoven jedinečný jasový interval, který je nepřekrývající se s ostatními intervaly. To činí prahování široce užívanou techniku pro segmentaci homogenních komponent v daném obraze [15] jako například odlišení objektů od pozadí [16] aj. Vlastní prahování je možné z hlediska charakteru výstupu rozdělit do těchto kategorií:

- **prosté prahování** - je zvolen pouze jeden nebo více prahů a výstupem je binární obraz (hodnoty pixelů pod prahem jsou transformovány na 0 a nadprahové hodnoty na 1 – transformační funkce je skoková),
- **poloprahování** – jasové hodnoty v rámci zvoleného intervalu zůstanou zachovány a mimo tento interval budou transformovány na 0 (výstupem je šedotónový obraz – transformační funkce je po částech lineární).

Přičemž z hlediska stanovování prahové hodnoty je možné prahování rozdělit na globální a lokálně adaptivní [13], které je možné dále rozdělit do několika subkategorií

[16]. Stanovení prahových hodnot je v praxi velmi problematické. Stanovit práh je obecně možné manuálně či s využitím některé z automatických metod. V rámci manuálního určení prahových hodnot je nejčastěji využit histogram daného obrazu, kdy prahová hodnota je zvolena v jeho sedle. Popřípadě je možné prahovou hodnotu stanovit na základě optimalizace z hlediska požadovaného výstupu, kdy uživatel hodnotí výstupní obraz a na základě nějž upravuje hodnotu prahu. Možnými způsoby automatického určení optimálních prahů jsou např. metoda Otsu ([17]), Kapur ([18]), Ridler ([19]) či metoda optimálního proložení histogramu Gaussovými křivkami (normálním rozložením) ([20]). V rámci adaptivního prahování není hodnota prahu prostorově invariantní (globální), ale je určována lokálně v rámci pohybujícího se okna, přičemž tento přístup je výhodný například v případech, kdy není v rámci obrazu zachováno rovnoměrné osvětlení. Volba vhodné metody a s tím souvisejících prahových hodnot je v praxi závislá na charakteru dané úlohy, a to z hlediska vstupních dat a hlavně na požadovaném výstupu. [13] [14]

2.1.2 Metoda rozvodí

Metoda rozvodí (z anglického „Watershed“) se nachází na pomezí hranově a regionově orientované segmentace. Princip této metody je možné vysvětlit s využitím geografický pojmů. Obraz lze chápat jako reliéf terénu, kde vrcholky (hřebeny) odpovídají maximálním jasovým hodnotám v daném obraze [14]. V rámci vlastní realizace tohoto algoritmu není příliš vhodné použít přímo vstupní obrazová data, výhodnější je použít gradientní mapu (parametrický obraz), která byla získána pomocí operátorů aproximujících gradient (první derivace) např. pomocí diferencí. Tyto diferenční operátory mají však tendence v obraze zvýrazňovat šum, proto je v některých případech výhodnější vytvořit distanční mapu, jejíž vytvoření je vhodné i v případech, kdy se objekty v obraze překrývají [14]. V rámci získané parametrické mapy představují hřebeny hranice oblastí (segmentů) a jsou nazývány rozvodí. Dále je možné rozeznat oblasti povodí, které odpovídají lokálním minimům. Vlastní princip této metody je možné popsat pomocí simulace povodně, kdy v oblastech lokálních minim dojde k perforaci povrchu a následnému ponořování (postupné zaplavování povodí), přičemž na hřebenech (rozvodích) jsou budovány myšlené přehrady (brání slití dvou oblastí), které následně vytvoří hranice segmentovaných oblastí [13]. Výhodou této metody je její robustnost, kdy vytváří automaticky spojitě a uzavřené hranice bez ohledu na šum. Nevýhodou může být tendence k častému přesegmentování. [13] [14] [21]

2.2 Texturní analýza

Textura patří mezi lokální charakteristiky obrazu. Obecně je možné říci, že textura je nedílnou součástí všech obrazů včetně těch medicínských, na jejímž základě lze v obraze rozeznávat a klasifikovat určité oblasti. Platí, že textury jsou komplexní vzory, které mají charakteristický jas, barvu, tvar a velikost. S jejich pomocí můžeme v obraze rozeznávat hranice, hrany, povrchy či jednotlivé struktury. Texturu můžeme popsat jako vzor v obraze, který souvisí s charakteristickými změnami intenzit pixelů, přičemž jednotlivé textury jsou velice různorodé a neexistuje jednotná definice. O textuře je však možné říci, že je pro ni klíčová pravidelnost opakování určitého vzoru (tento předpoklad však neplatí ve všech případech např. u slabých textur). Tyto opakující se oblasti nazýváme primitiva a jsou pro danou texturu charakteristické. Právě podle velikosti primitiv je možné textury dělit na hrubé a jemné, na základě pravidelnosti opakování primitiv pak dále na slabé a silné textury. Silné textury se vyznačují pravidelným uspořádáním jednotlivých primitiv, zatímco slabé textury jsou uspořádané víceméně náhodně. Další dělení textur je možné podle určité směrovosti, kterou v nich můžeme rozeznat. Podle tohoto dělení rozlišujeme textury izotropní (bez směrovosti) a směrové (patrná směrovost uspořádání primitiv). [13] [22] [23] [24]

V rámci vlastní texturní analýzy je usilováno o získání popisu textury, který bude následně dále využit např. v rámci procesu segmentace či klasifikace. Tímto popisem je myšlen vektor příznaků, přičemž příznak je popisná veličina charakterizující danou texturu. V rámci klasifikace dojde k zařazení textury do určité třídy, kam právě na základě svých texturních příznaků náleží. Teoreticky by mělo platit, že jestliže jsou si dané dvě textury podobné, jsou si podobné i jejich vektory příznaků. Pro přesnost klasifikace platí, že čím větší oblast textury vyhodnocujeme, tím je klasifikace přesnější, avšak dojde ke zhoršení prostorového rozlišení klasifikace. V rámci segmentace s využitím texturních příznaků dojde k rozdělení obrazu do oblastí, které jsou právě na základě těchto charakteristik s určitou tolerancí homogenní. Toto rozdělení je však poměrně náročné. Předem totiž není známo, jaké textury se v obraze vyskytují, jaký je jejich počet a ani jejich oblastní výskyt. Pro úlohu segmentace však není potřeba znát apriorní informace o výskytu textur, i bez těchto znalostí je totiž možné oddělit od sebe oblasti, v rámci kterých je textura podobná. Podstatné je však určit, jakým způsobem od sebe jednotlivé oblasti odlišovat. [13] [22] [23] [24] [25] [26] [27]

Obecně je možné metody texturní analýzy rozdělit do těchto kategorií: strukturní metody, statistické metody, metody založené na modelech a transformační metody. Přičemž každá kategorie má své výhody i nevýhody i využití v rámci texturní analýzy [28]. Popis jednotlivých kategorií je obsažen v následujících sekcích této práce.

2.2.1 Statistické metody

Statistické přístupy k popisu textury se nesnaží popsat hierarchickou strukturu textury, charakterizují texturu nepřímou, a to v rámci vlastností řídících distribuci a vztahy mezi pixely v šedotónovém obraze. Jednou z hlavních definičních vlastností textury je prostorová distribuce stupňů šedi v obraze. Obraz o rozměrech $M \times N$, s G stupni šedi můžeme popsat vztahem (2-1) [23]:

$$I(x, y), 0 \leq x \leq M - 1, 0 \leq y \leq N - 1 \quad (2-1)$$

kde I vyjadřuje jasovou hodnotu pixelu o prostorových souřadnicích x, y . Statistické metody je možné rozdělit na statistické metody prvního řádu a statistické metody druhého řádu, přičemž obě kategorie dosahují dobrých výsledků v rámci selektivity. [22] [23] [24] [28] [29]

2.2.1.1 Statistické metody prvního řádu

Tato kategorie texturní analýzy je založena na histogramu daného obrazu, kde jednotlivé sloupce reprezentují četnost voxelů o stejné intenzitě (úrovně šedi v šedotónovém obraze). K danému obrazu je tedy přistupováno jako ke statistickému souboru pixelů a jejich vzájemná poloha je naprosto ignorována. Do vlastní analýzy je pro daný objekt zahrnuta pouze jediná hodnota znaku a tou je stupeň šedi (jasová hodnota). Označme si n -tý centrální moment M_n , který je definován vztahem (2-2) [23]:

$$M_n = \sum_{i=0}^{G-1} (x(i) - \mu)^n p(i), \quad (2-2)$$

kde μ značí střední hodnotu, G označuje počet stupňů šedi a $p(i)$ pravděpodobnost, že daný pixel má hodnotu stupně šedi $x(i)$. Přičemž platí, že nultý centrální moment se vždy rovná 1 a první centrální moment je roven 0. Druhý centrální moment je označován jako rozptyl, který souvisí kontrastem dané oblasti. Z rozptylu je možné odvodit další statistické míry jako směrodatnou odchylku, definována vztahem (2-3) [23], či relativní hladkost, definována vztahem (2-4) [23]. [22] [23] [28] [29]

$$S = \sqrt{M_2} \quad (2-3)$$

$$R = 1 - \frac{1}{1 + M_2} \quad (2-4)$$

Relativní hladkost nabývá hodnot v rozmezí od 0 do 1. Nulovou hodnotu relativní hladkosti má homogenní plocha (rozptyl je v ní nulový), je patrné že s rostoucím

rozptylem roste i hodnota relativní hladkosti, která se postupně blíží jedné [23]. Dále je možné k popisu textury využít koeficient špičatosti K , definován vztahem (2-5) [23], a koeficient šikmosti SK , definován vztahem (2-6) [23]. [23]

$$K = \frac{M_4}{S^4} - 3 \quad (2-5)$$

$$SK = \frac{M_3}{S^3} \quad (2-6)$$

K charakterizaci textury se používají i další příznaky jako informační entropie a uniformita. Informační entropie je značena H a je definována vztahem (2-7) [23]:

$$H = -\frac{1}{\ln 2} \sum_{i=0}^{G-1} h(i) \ln h(i), \quad (2-7)$$

kde $h(i)$ vyjadřuje pravděpodobnost pro i -tý sloupec normovaného histogramu a G označuje počet stupňů šedi. Uniformita je definována vztahem (2-8) [23]:

$$U = \sum_{i=0}^{G-1} h^2(i), \quad (2-8)$$

kde $h(i)$ vyjadřuje pravděpodobnost pro i -tý sloupec normovaného histogramu a G označuje počet stupňů šedi.

2.2.1.2 *Statistické metody druhého řádu*

Tyto metody využívají texturní příznaky odvozené z matice současného výskytu stupňů šedi (z anglického „Gray Level Co-Occurrence Matrix“ – zkráceně GLCM). Jak již bylo zmíněno v předchozí sekci této práce, statistické metody prvního řádu ignorují informaci o vzájemné pozici dvou pixelů, to již u metod druhého řádu neplatí. Statistické metody druhého řádu jsou založeny na pravděpodobnosti výskytu dvou pixelů o stejné intenzitě, jež mají vůči sobě definovanou vzájemnou polohu. [22] [23] [28] [29]

Matice současného výskytu

Matice současného výskytu obsahuje informaci o vzájemném vztahu jasu dvou definovaných pixelů. Tato matice hodnotí stupně opakovaných kombinací jasových intenzit (f, f') pixelů, které se vyskytují ve vzájemně definované poloze, a to ve vzdálenosti Δr a směru ϕ , přičemž v kartézské souřadné soustavě je možné vzájemnou

polohu definovat diferencemi Δx a Δy . Vzájemná poloha může být definována i pomocí relativní pozice druhého pixelu vůči poloze prvního pixelu např. druhý pixel leží těsně vpravo od prvního (v zápise výpočtů koincidenčních matic má tento druhý pixel souřadnice [1 0]). Koincidenční matice je čtvercového tvaru o rozměrech $n \times n$, kde n je počet stupňů šedi v daném obraze. Vlastní výpočet probíhá následujícím způsobem – v prvním kroku je definována dvojice pixelů, pro kterou výpočet probíhá. Hodnoty jasu těchto dvou pixelů představují indexy prvku v matici, když dojde k vyčerpání všech možných dvojic pixelů, hodnota indexu se zvýší o jedničku a je hledán výskyt dvojic pixelů o těchto nových jasových intenzitách. Následně je každý prvek matice vydělen součtem všech prvků, čímž dostane prvek a_{ij} význam pravděpodobnosti, s jakou se v daném obraze vyskytuje dvojice pixelů (definovaná vstupním vektorem) s jasovými hodnotami i, j . V rámci vlastního výpočtu matice současného výskytu pracujeme s parametrem d , přičemž tento parametr vyjadřuje vzdálenost od prvního definovaného pixelu a také směr (definovaný úhlem), ve kterém se druhý pixel nachází. Tento parametr d je možné vyjádřit čtyřmi způsoby: pro úhel $\phi = 0^\circ$ je d rovno (1,0), pro úhel $\phi = 45^\circ$ $d = (-1,1)$, pro $\phi = 90^\circ$ $d = (0,1)$ a pro $\phi = 135^\circ$ $d = (-1,-1)$. [22] [23] [24] [28] [29]

Matematicky lze výpočet koincidenční matice pro směrový vektor $d = (\Delta x, \Delta y)$ a obraz o rozměrech $(M + \Delta x, N + \Delta y)$ zapsat následujícím způsobem, vztah (2-9) [23]:

$$GLCM_d[i, j] = \sum_{p=1}^n \sum_{q=1}^m \begin{cases} 1: f(p, q) = i \text{ a současně } f(p + \Delta x, q + \Delta y) = j \\ 0: \text{jinak} \end{cases}, \quad (2-9)$$

kde $f(p, q)$ je hodnota intenzity pixelu o souřadnicích p, q , která je rovna hodnotě i a $f(p + \Delta x, q + \Delta y)$ je jasová hodnota intenzity pixelu na pozici $[p + \Delta x, q + \Delta y]$ a ta je rovna hodnotě j .

Jak již bylo zmíněno, koincidenční matice představuje způsob zohlednění i vzájemné polohy pixelů a ne pouze pravděpodobnostního charakteru množiny pixelů v rámci daného obrazu. Matice současného výskytu nachází hlavní uplatnění v rámci klasifikace a segmentace obrazových dat, přičemž pro každou koincidenční matici, definovanou vektorem d , je možné spočítat 14 příznaků (dle Haralicka [30]), tyto příznaky spolu s vzorci pro jejich výpočet je možné nalézt v rámci tohoto zdroje [30]. [22] [23] [28] [29]

„Run-Length“ matice

Statistické metody druhého řádu vycházející z matice délky běhů (z anglického „Gray Level Run-Length Matrix“ zkráceně GLRLM), patří ke statistickým přístupům vyššího řádu, protože v průběhu vlastní analýzy dochází k zohlednění vzájemné polohy více pixelů. Princip této metody vychází z úvahy, že texturu je možné charakterizovat

četností a velikostí oblastí s prostorově invariantní hodnotou jasu (v šedotónovém obraze se jedná o oblasti se stejným odstínem šedi). Ty jsou odhadovány prokládáním obrazu přímkami se směrem θ . Nejčastěji jsou používány pouze rovnoběžky se souřadnicovými osami, případně s osami jednotlivých kvadrantů. V rámci těchto prokládaných přímek je počítána délka úseků (běhů) o stejné jasové intenzitě. Výsledné délky běhů jsou vynášeny do matice o rozměrech $i \times j$, kde i je počet stupňů šedi v daném obraze a j je nejdelší souvislý úsek jedné jasové intenzity. Pro daný směr θ je v prvku $\Pi_{i,j}(\theta)$ matice $\Pi(\theta)$ počet souvislých intervalů jasové intenzity i a délky j , které jsou v analyzovaném obraze zachyceny při jeho úplném pokrytí přímkami o zadaném směru θ . [22] [23] [24] [28] [31]

Místo matice absolutních četností $\Pi(\theta)$ je vhodnější využívat matici relativních četností $\pi(\theta)$. Ta má rozměry $G \times R$, kde G označuje počet stupňů šedi v obraze a R délku nejdelšího souvislého úseku. Matice relativních četností má charakter pravděpodobnostní funkce diskrétního dvojrozměrného náhodného rozdělení, tudíž lze zavést marginální pravděpodobnostní funkce vyjádřené vztahy (2-10) [31] a (2-11) [31]:

$$r_j(\theta) = \sum_{i=1}^G \pi_{i,j}(\theta) \quad (2-10)$$

$$g_i(\theta) = \sum_{j=1}^R \pi_{i,j}(\theta). \quad (2-11)$$

Zatímco u matice současného výskytu sloužily marginální pravděpodobnosti jako pomocné proměnné k výpočtu některých texturních příznaků, u „Run-Lenght“ matice je možné všechny texturní míry z této matice počítané vyjádřit výhradně pomocí jedné či druhé marginální pravděpodobnostní funkce. Tento fakt v praxi představuje snížení výpočetní náročnosti výpočtu jednotlivých texturních příznaků (přičemž všechny vzorce je možné najít v rámci tohoto zdroje [31]). [22] [23] [31]

2.2.2 Strukturní metody

Strukturní přístupy k reprezentaci textury jsou založeny na výskytu primitiv v dané textuře a jejich prostorovém uspořádání. Pokud se zabýváme pouze popisem primitiv, a ne jejich prostorovým uspořádáním, jedná se o mikrotexturní analýzu. V případě makrotexturní analýzy je již bráno v potaz prostorové uspořádání primitiv ve větší celky. U strukturních přístupů k analýze textury je však nejprve nutné nalézt a identifikovat všechny typy primitiv, které se v rámci daného obrazu vyskytují. Následně je obraz podroben analýze z hlediska prostorového uspořádání již nalezených primitiv, přičemž je zásadní odhalit všechna možná prostorová uspořádání. Výhodou těchto přístupů k popisu

textury je, že poskytují dobrý symbolický popis daného obrazu. U přírodních textur (tzn. textur vyskytujících se přirozeně) je však definování tohoto popisu náročné, a to z důvodu vysoké proměnlivosti obou přístupů (mikrotexturní i makrotexturní analýzy) a nejasných hranic mezi nimi. [22] [28]

2.2.2.1 Mikrotexturní analýza

V rámci tohoto přístupu existuje předpoklad, že analyzovaná textura obsahuje náhodné či pravidelné přechody jasových intenzit, které jsou nazývány mikro-prvky (primitiva). Těmito mikro-prvky jsou myšleny hrany, linie nebo shluky bodů, které mají specifickou prostorovou distribuci jasových intenzit. Informace o těchto lokálních prvcích mohou být získány pomocí konvoluce obrazu s maskami, které představují model vzorů zmíněných primitiv. Konkrétně se jedná o směrové masky (rotované impulsní charakteristiky) lineárních filtrů aproximujících první a druhé derivace. Těmito maskami jsou myšleny masky odvozené K. I. Lawsem, které jsou definovány pro dvojrozměrný i třírozměrný prostor. Všechny používané masky jsou odvozeny na základě vektorů v jednorozměrném prostoru, které mohou být složeny ze tří nebo pěti prvků. Výsledné masky ve dvojrozměrném prostoru vznikají roznásobením všech vektorů (vždy pouze v rámci vektorů o stejné velikosti) z nichž jeden je vždy transponovaný. Obdobným způsobem lze vytvořit masky i pro trojrozměrný prostor, přičemž je možné vytvořit 27 popřípadě 125 masek (v závislosti na velikosti vektorů použitých pro jejich vytvoření). Zmiňované vektory je možné rozdělit do pěti řad a to: L, E, S, W a R. Přičemž jednotlivé vektory slouží k zvýraznění či získání jiných parametrů daného obrazu: vektory řady L slouží k určení průměrného stupně šedi, vektory řady E k získání hranových prvků, vektory řady S slouží k získání (zvýraznění) skvrn, vektory řady W slouží k zvýraznění vln v obraze a vektory řady R slouží k zvýraznění vlnek. [22] [23] [28] [32]

2.2.3 Metody založené na modelech a transformační metody

Metody založené na modelech používají stochastické a fraktální modely k interpretaci struktury obrazu, čímž je myšleno získání modelu daného obrazu. Takto získané odhady parametrů modelu jsou následně použity k analýze daného obrazu. V praxi je však použití stochastických modelů velice výpočetně náročné, a proto se více používají fraktální modely, které se ukázaly být vhodné k modelování přírodních struktur. Vytvořené modely však postrádají informace o prostorové selektivitě, a proto nejsou příliš vhodné pro popis lokálních struktur obrazu. [22] [28]

Transformační metody využívají k texturní analýze různé typy transformací. Těmito transformacemi jsou Fourierova, Gaborova a vlnková transformace. Tyto operace reprezentují obraz v rozměru, jehož souřadný systém má interpretaci blízkou

charakteristice textury (např. frekvence nebo velikost). Tyto přístupy tedy poskytují informace o frekvenční a prostorové doméně daného obrazu, přičemž vlastnosti obou domén mohou být použity k filtraci obrazu a zisku relevantních informací. Metody založené na Fourierově transformaci dosahují v praxi nepříliš dobrých výsledků, protože poskytují málo informací o prostorové lokalizaci. Gaborovy filtry oproti tomu poskytují prostředky pro lepší prostorovou lokalizaci. Jejich použitelnost je však v praxi limitována, a to z důvodu použití více filtrů k zisku výsledku, v rámci kterého by bylo možné lokalizovat prostorové struktury v přírodních texturách. Vlnková transformace má oproti dříve zmíněným transformacím řadu výhod:

- změny prostorového rozlišení umožňují reprezentovat textury na nejvhodnějším měřítku,
- je dostupná celá řada možností pro vlnkovou transformaci, proto je možné zvolit takové vlnky (nastavení), které se hodí pro texturní analýzu v konkrétním případě,

kvůli nimž je vlnková transformace vhodná pro texturní segmentaci. Její nevýhodou však může být translační-invariantnost. [22] [28] [33]

Do těchto metod spadá i „Multi-channel“ filtrace (multi-kanálová), přičemž tento princip se zdá být velice vhodnou deterministickou metodou pro texturní analýzu. Některé z realizací této metody jsou založené na „Gaussovsko-Markovových“ texturních modelech (modely náhodných polí). Další realizace využívají autoregresní modely (Autoregressive models – AR modely) nebo hybridní přístupy, které kombinují statistické a strukturní techniky. [22] [28] [33]

2.2.3.1 *Spektrální analýza*

Spektrální analýza spočívá ve využití diskrétní Fourierovy transformace (pro 2D funkci definována vztahem (2-12) [13][23]), čímž získáme informace o spektrálních vlastnostech dané oblasti obrazu. Výstupy této transformace jsou komplexního charakteru, na základě nichž je možné získat informace o fázi (definovaná jako úhel komplexního čísla) a amplitudě (získaná pomocí absolutní hodnoty) dané oblasti textury. Tyto parametry mohou být dále využity k výpočtu výkonu (definován jako amplituda umocněná na druhou) či k získání informací o lokálních vlastnostech spektra v daných frekvenčních pásmech, čímž je možné získat další důležité příznaky pro texturní analýzu. [13] [22] [23]

$$F_{m,n} = \frac{1}{N} \sum_{i=0}^{N-1} \sum_{k=0}^{N-1} f_{i,k} e^{-j\frac{2\pi}{N}(mi+nk)}, \quad i, k, m, n = 0, 1, \dots, N-1, \quad (2-12)$$

kde f vyjadřuje hodnotu pixelu obrazu v originální oblasti na pozici i, k , F odpovídá hodnotě komplexního spektrálního koeficientu na souřadnicích m, n a N je počet pixelů pro horizontální a vertikální rovinu (pro zjednodušení uvažován čtvercový obraz).

2.3 Tvarová analýza


Tvarová analýza slouží k získání příznaků založených na tvarech daných objektů. Tvar je důležitý vizuální prvek a je jedním ze základních prvků používaných k popisu obsahu obrazu. Získání tvarové reprezentace a popisu je však náročnou úlohou. V praxi je totiž kontura často poškozena řadou faktorů, mezi něž patří např. šum v obraze, defekty, aj. [34]. Tvarovou reprezentaci a popisné techniky je obecně možné klasifikovat do dvou tříd, a to na metody vycházející z kontury objektu (obrys) a metody vycházející z regionu objektu, na jejichž základě je možné získat vlastní tvarové příznaky. Obě kategorie je možné dále rozdělit na metody založené na strukturálním přístupu (tvar reprezentován pomocí segmentů) a metody založené na globálním přístupu (tvar reprezentován jako celek). Tvarová reprezentace obecně hledá efektivní a perceptuálně důležité tvarové příznaky založené na informaci z kontury daného objektu či z kontury a vnitřního obsahu daného objektu. Mezi tyto příznaky patří například: tvarový podpis, podpisový histogram, tvarové momenty a křivky, tvarové souvislosti, spektrální prvky atd. [34]

3. Klasifikační metody

Klasifikaci lze obecně definovat jako rozdělení skupiny objektů do předem definovaného počtu tříd, kam na základě svých vlastností (příznaků) náleží, přičemž platí, že v rámci dané třídy do ní zařazené objekty mají dostatečně podobné vlastnosti. Právě vlastnosti objektů, na jejichž základě je prováděna vlastní klasifikace, definují klasifikační kritéria. Musí platit, že klasifikace je úplná, což znamená, že každý objekt musí patřit do nějaké třídy a nemůže být současně zařazen do více tříd [35]. Vlastní klasifikace je realizována pomocí klasifikátoru. Obecně je možné klasifikační úlohu popsat tímto způsobem: objekt zájmu je podroben analýze, čímž jsou získány popisné veličiny (příznaky), které dále vstupují do klasifikátoru, jež daný objekt na základě rozhodovacího pravidla zařadí do klasifikační třídy, kam náleží. [35]

3.1 Klasifikátory

Klasifikátor je algoritmus, jehož vstupem je charakteristika daných dat (vektor příznaků) a disktrétním výstupem je hodnota identifikující klasifikační třídu, kam objekt náleží [35]. Funkcí klasifikátoru je tedy zařazení objektu do klasifikační třídy, což je prováděno na základě rozhodovacího pravidla. Schéma klasifikátoru je uvedeno na obrázku: Obrázek 3-1, kde X reprezentuje vstupní data (vektor příznaků), $d(X)$ označuje rozhodovací pravidlo, jehož argumentem je X a ω_r je identifikátor klasifikační třídy. Rozhodovací pravidlo je stanoveno v rámci bloku učební fáze, přičemž pracuje na základě vzdálenosti či podobnosti mezi vstupní datovou reprezentací a vzorem klasifikační třídy, dále pak na základě hranic rozdělující prostor příznaků, či pomocí funkcí, které určují míru příslušnosti k dané klasifikační třídě (tzv. diskriminační funkce), případně pak na základě doplňkových logických pravidel [35].



Obrázek 3-1: Obecné schéma klasifikátoru. Převzato z [35].


Rozhodovací pravidlo je možné vyjádřit tímto vztahem [35]:

$$\omega_r = d(X, q), \quad (3-1)$$

kde ω_r je identifikátor klasifikační třídy, X reprezentuje vstupní data (vektor příznaků) a q představuje nastavení klasifikátoru. Toto nastavení je realizováno v trénovací neboli učební fázi. Obecně je možné rozlišit dvě metody učení, a to učení s učitelem a učení bez učitele. V rámci metody učení s učitelem je k dispozici trénovací množina se známými výstupy (příslušností ke klasifikační třídě). U metod učení bez učitele není příslušnost ke klasifikační třídě předem známá, sem náleží například metody shlukové analýzy. [35] [36]

3.1.1 Příznakový klasifikátor

Tento typ algoritmu má tolik vstupů, kolik je příznaků v příznakovém vektoru, a jeden diskretní výstup, jehož hodnota definuje klasifikační třídu, kam byl klasifikovaný objekt zařazen. Schéma příznakového klasifikátoru je patrné na obrázku: Obrázek 3-2, kde X značí vektor příznaků ($X_1, X_2, \dots, X_N$), $d(X)$ označuje rozhodovací pravidlo a ω_r je identifikátor klasifikační třídy. Vlastní klasifikaci lze u tohoto typu algoritmu rozdělit na paralelní klasifikaci (zpracovávání vektoru příznaků jako celku) a sekvenční klasifikaci (zpracovávání a získání příznaků postupně). Klasifikační třídy lze v příznakovém prostoru vymezit několika různými způsoby a to pomocí: diskriminační funkce, kritéria minimální vzdálenosti, Bayesovského klasifikátoru (kritérium minimální chyby), neuronových sítí, podpůrných vektorových strojů (z anglického „Support Vector Machines“) či shlukové analýzy. [35]



Obrázek 3-2: Schéma obecného příznakového klasifikátoru. Převzato z: [35].

3.1.2 Příznaky

Příznakem se rozumí kvantitativní či kvalitativní vlastnost daného objektu, přičemž objekt může být popsán více příznaky. Soubor těchto příznaků je uspořádán do příznakového vektoru, který může být dále součástí příznakového prostoru, jehož dimenze je dána počtem příznaků. Obecně platí, že pro správnou funkci klasifikátoru je nutné dostatečné množství informací, což znamená, že čím více informací vstupní data nesou, tím kvalitnější bude výsledná klasifikace. Oproti tomu však s rostoucím počtem příznaků roste výpočetní náročnost a výpočetní čas klasifikátoru, což vede k hledání kompromisu mezi správností klasifikace a technickou náročností realizace. Před vlastní

klasifikací je tedy nutné redukovat vektor příznaků o nerelevantní příznaky, jež nejsou pro zařazení do klasifikační třídy podstatné (nenesou dostatek informace). Obecně se dá říci, že vhodnými příznaky jsou ty, jež jsou vůči sobě nekorelované a mající maximální vzdálenost mezi třídami a minimální rozptyl uvnitř tříd. Vlastní redukci vektoru příznaků je možné realizovat s využitím statistických metod, jako jsou: korelační analýza, analýza hlavních komponent či diskriminační analýza [37]. [35]

3.2 Shluková analýza

Shluková analýza je postup, pomocí něhož objektivně seskupujeme jedince do skupin na základě jejich vzájemných podobností a rozdílů. Obecně je tedy možné říci, že shlukování je seskupování vůči sobě podobných objektů. Při vlastním seskupování objektů do shluků, se snažíme dosáhnout stavu, aby si členové shluku byly vzájemně podobné a zároveň si nebyly příliš podobné s objekty v jiných shlucích (tzn. mimo shluk než, ke kterému byly zařazeny). Shluková analýza probíhá vždy na množině objektů, přičemž každý objekt je definován pomocí množiny příznaků (získaných například s využitím texturní analýzy), a platí, že počet příznaků je stejný pro každý objekt. [22] [38] [39]

Podle hranic mezi shluky je možné vlastní shlukování rozdělit na tvrdé a měkké (tzv. fuzzy). Tvrdé shlukování je možné dále dělit na nehierarchické a hierarchické, které se dále dělí na divizní a aglomerativní [39]. O hierarchické shlukové analýze je možné říci, že výsledkem je takový systém skupin a podskupin, že každá skupina může obsahovat několik podskupin nižšího řádu a sama může být součástí skupiny vyššího řádu. Přičemž vlastní výsledek se dá graficky znázornit pomocí dendrogramu (tzv. vývojového stromu). Mezi metody tohoto typu shlukové analýzy patří například metoda UPGMA (z anglického „Unweighted Pair Group Method with Arithmetic Mean“). Nehierarchická shluková analýza rozděluje objekty do několika shluků stejného řádu. Tento typ shlukování se využívá v případech, kdy data nevykazují hierarchickou strukturu, a navíc jsou objemná. Metodou nehierarchické shlukové analýzy je například algoritmus k-means (k-průměrů), přičemž u tohoto postupu je nutné předem definovat počet shluků, do nichž bude vlastní dělení probíhat. Tento zvolený počet shluků musí být vždy menší než počet shlukovaných objektů. Ideální počet shluků je možné objektivně určit na základě analýzy dendrogramu či s využitím matematických metod, např. analýza mezishlukových/vnitroshlukových vzdáleností nebo metoda silhouette, či s využitím Mantelova testu [39]. Často je počet shluků stanoven na základě expertních znalostí a zkušeností analytika a praktického významu výstupu [39]. V některých případech je však možná situace, kdy zvolený počet shluků je pouze arbitrární, např. když vstupní data nevykazují existenci

přirozených shluků [39]. Obecný postup shlukové analýzy se dá rozdělit do několika kroků: získání matice dat (změření či určení příznaků), standardizace matice dat, výpočet matice podobností (nebo vzdáleností mezi objekty např. Euklidovská vzdálenost), realizace shlukové metody, přerovnání dat a matice podobností a v posledním kroku výpočet korelačního koeficientu pro hodnoty z matice vzdáleností a matice vzdáleností odvozených z dendrogramu (vyjadřuje zkreslení vzniklé vytvořením dendrogramu). [22] [38] [39] [40]

3.2.1 K-means


Metoda k-means patří mezi metody nehierarchické shlukové analýzy a je vhodná pro data, která nevykazují hierarchickou strukturu nebo jsou objemná. Vlastní dělení probíhá do shluků o stejném řádu, přičemž počet shluků je nutné zvolit před vlastním zahájením algoritmu shlukování. Hlavním cílem je vytvoření takových skupin v mnohazměrném prostoru, pro které platí, že je mezi nimi největší vnitroskupinová podobnost. Výsledkem by ideálně měly být shluky, které jsou od sebe co nejvíce odděleny. [22] [40] [41] [42]

K-means shlukování probíhá tak, že v prvním kroku je mezi vstupními objekty náhodně zvoleno K iniciačních centroidů, kde je K počet shluků, do kterých má proběhnout dělení, a centroidem je myšlen střed shluku. K těmto iniciačním centroidům jsou postupně přiřazovány objekty na základě jejich Euklidovské vzdálenosti. Probíhá tedy výpočet vzdáleností jednotlivých objektů ke všem centroidům, a to dle následujícího vzorce [38]:

$$C_E(a, b) = |a - b| = \sqrt{\sum_{i=1}^N (a_i - b_i)^2}, \quad (3-2)$$

kde a vyjadřuje souřadnice objektu a b souřadnice centroidu a N je počet souřadnic. Následně je objekt přiřazen k centroidu, ke kterému má nejmenší Euklidovskou vzdálenost. Tímto způsobem jsou všechny objekty přiřazeny k nějakému centroidu a vznikne tak K shluků. Následně je proveden přepočít souřadnic všech centroidů. Nové souřadnice jsou určeny jako průměrné souřadnice objektů přiřazených k danému centroidu (jednotlivé souřadnice jsou sečteny a děleny počtem objektů zařazených do shluku). V dalším kroku probíhá znovu zařazování objektů k těmto nově vzniklým centroidům, a to stejným způsobem, jak v kroku předcházejícím, přičemž objekt může zůstat zařazen k vlastnímu centroidu anebo být zařazen do jiného shluku. Toto zařazování objektů a přepočít souřadnic centroidů probíhá iterativně do doby, dokud se už počet objektů zařazených k jednotlivým centroidům nemění (nemění se tedy ani souřadnice

centroidů). Po splnění této podmínky je algoritmus ukončen a výsledkem je K shluků, ke kterým jsou zařazeny vstupní objekty. Graficky je celý postup znázorněn na obrázku: Obrázek 3-3. [22] [38] [40] [41] [42] [43]



Obrázek 3-3: Princip shlukové analýzy a) Iniciační centroidy (barevné kruhy) a vstupní objekty (šedé čtverce); b) Objekty zařazené k iniciačním centroidům; c) Posun centroidů; d) Zařazení objektů k novým centroidům. Převzato z: [38].

3.2.2 Fuzzy k-means

Fuzzy k-means je modifikací klasické shlukovací metody k-means, přičemž po vlastním shlukování může každý z objektů náležet do více shluků, a to s určitými stupni příslušnosti. Ty vyjadřují pravděpodobnost, že daný objekt náleží do určitého shluku. Tato funkce příslušnosti je definována [44]:

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}}, \quad (3-3)$$

kde u_{ij} je stupeň příslušnosti bodu x_i ke shluku j (platí, že suma stupňů příslušnosti daného bodu přes všechny shluky je rovna 1), c_j je střed shluku j , C je celkový počet shluků a parametr m je váhovací exponent, jež kontroluje tvar fuzzy funkce příslušnosti (v případě, že m je rovno 1, se jedná o klasický algoritmus k-means). Fuzzy k-means je iterativní algoritmus, přičemž v každé iteraci je minimalizována funkce vyjádřená vztahem [44]:


$$\sum_{i=1}^N \sum_{j=1}^C u_{ij} \|x_i - c_j\|^2, \quad 1 \leq m \leq \infty, \quad (3-4)$$

kde N vyjadřuje celkový počet objektů a C je celkový počet shluků. [42] [44]

3.3 Klasifikace algoritmem náhodného lesa

Náhodný les je algoritmus, jež může být využit pro klasifikační i regresní úlohy, náležící mezi souborové metody strojového učení [45]. V rámci tohoto algoritmu je vytvářen soubor modelů, který využívá výstupy z mnoha různých modelů, v sobě obsažených, pro získání celkového výstupu, přičemž modelem je myšlen rozhodovací strom. Jednotlivé rozhodovací stromy jsou tvořeny na základě učební množiny, a to mechanismem CART [46] (z anglického: „Classification and Regression Tree“). [45]

Konkrétně se jedná o binární rozhodovací stromy, jejichž rozhodovací pravidla jsou tvořena na základě jednoduchého prahování proměnných ze vstupní množiny, přičemž koncové listy (tzv. terminační listy) obsahují zařazení vstupních proměnných do konkrétní klasifikační třídy. Zjednodušeně se celý proces klasifikace rozhodovacím stromem dá popsat tak, že vstupní proměnné postupně procházejí vytvořeným vícepatrovým modelem až do doby, kdy jsou zařazeny do odpovídající třídy [47]. V rámci sestavování rozhodovacího stromu T dochází k postupným dělením trénovací množiny X na navzájem neprolínající se oblasti, kdy každá oblast odpovídá jedné klasifikační třídě [47]. Vlastní rozhodovací strom T je tvořen uzly, v rámci nichž dochází k porovnávání jednotlivých prvků příznakového vektoru $\mathbf{x} \in X$, kdy na základě těchto porovnávání vektor postupně propadne až k jednomu z terminačních listů. Pro binární strom platí, že rozděluje prostor vstupní množiny na kvádry, jejichž hrany jsou rovnoběžné se souřadným systémem tohoto prostoru (viz. Obrázek 3-4). V rámci tohoto typu stromu dochází k porovnávání prvků příznakového vektoru na základě splnění nerovnosti $x_i \leq \alpha$, kde x_i je i -tý prvek příznakového vektoru $\mathbf{x}$ a α označuje zvolený práh, přičemž tato definovaná nerovnost je označovaná jako rozhodovací pravidlo. [47] [48]




Obrázek 3-4: Ukázka rozdělení prostoru trénovací množiny (vpravo) na základě příslušného rozhodovacího stromu (vlevo), kdy probíhá dělení do tří klasifikačních tříd. Převzato z: [48].

Obecně platí, že výsledný tvar stromu je značně ovlivněn volbou rozhodovacího pravidla, ale také pořadím, ve kterém jsou prvky příznakových vektorů porovnávány [48]. Obecně může práh nabývat nekonečně mnoha hodnot, ale na základně trénovací množiny X je možné vymezit konečnou množinu hodnot, jež je nutné pro získání prahu α_i otestovat. Při konstrukci vlastního stromu dochází k dělení vstupní trénovací množiny X na podmnožiny X_t a to na základě jednotlivých rozhodovacích pravidel, přičemž platí, že ze všech možných rozdělení X_t je zvoleno to, které nejlépe splňuje rozdělující kritérium (pro klasifikační úlohy je využíváno tzv. „Gini“ kritérium [46]). Na základě tohoto kritéria, definovaného jako míra rozmanitosti uzlu, je možné kvalitativně porovnávat vzniklá rozdělení X_t . Zmiňovaná míra rozmanitosti uzlu je definována jako entropie spjatá s daným uzlem (nulová v případě, že všechny vektory uvnitř množiny náleží do jedné klasifikační třídy) [47], přičemž cílem rozhodovacího kritéria je zvolit takové rozdělení uzlu, proto které dojde k nejvyššímu nárůstu rozmanitosti daného uzlu vůči dceřiným uzlům. [46] [47] [48]

Narůstání stromu je nutné regulovat, a to na základě zastavující podmínky. Ta může být definována prahem, který určuje minimální potřebný nárůst rozmanitosti uzlu, či na základě minimálního počtu vektorů uvnitř podmnožin vzniklých dělením daného uzlu. Přičemž uzel, který jednu z těchto podmínek splňuje je označen za list stromu, kdy musí platit, že každému listu je přiřazena odpovídající klasifikační třída. Konkrétně je listu přiřazena taková třída, jež je uvnitř dané podmnožiny X_t nejčastěji zastoupena. [47] [48]

Nevýhodou rozhodovacího stromu je samotný princip jeho sestavování, kdy výsledný tvar stromu je výhradně závislý na trénovací množině X . Přičemž s každou změnou trénovací množiny dojde ke změně jeho tvaru, což může vést k nárůstu chyby klasifikace [47]. Algoritmus náhodného lesa tento nedostatek eliminuje zapojením více (v praxi několika set) rozhodovacích stromů do vlastního procesu klasifikace. Tvorba rozhodovacích stromů pro náhodný les je založena na CART mechanismu, avšak s řadou modifikací. Trénovací množina X je konkrétně algoritmem bootstrap aggregating náhodně rozdělena na n množin, $X_{(n)}$, obsahujících $N_{(n)}$ prvků, kdy platí $N_{(n)} \leq N$. Přičemž pro každou množinu $X_{(n)}$ je vytvořen vlastní rozhodovací strom, pro jehož tvorbu je vždy využita jiná část ze vstupní trénovací množiny X . Zbývající prvky z trénovací množiny, nepoužité pro tvorbu daného rozhodovacího stromu, jsou někdy nazývané jako tzv. out-of-bag vzorky a jsou dále využity pro testování přesnosti vytvořeného modelu (tzv. out-of-bag chyba) [45]. Další modifikací je náhodný výběr k příznaků pro tvorbu rozhodovacího pravidla v rámci jednotlivých uzlů, kdy parametr k může být zvolen uživatelem, či je určen vlastním algoritmem náhodného lesa. Tím je zaručen pokles korelace mezi jednotlivými stromy, přičemž bylo prokázáno, že s klesající korelací klesá

i klasifikační chyba [45]. Klasifikace neznámého vektoru x vytvořeným modelem náhodného lesa probíhá tak, že je tento vektor přiveden na vstupy všech stromů $T_{(n)}$, v rámci nichž dojde k zařazení vektoru x do jedné z klasifikačních tříd ω_i , kde $i = 1, 2, \dots, M$ (celkový počet tříd). Přičemž finální zařazení y je dáno jako modus rozhodnutí jednotlivých stromů. [47]



Obrázek 3-5: Princip klasifikace neznámého vektoru x algoritmem náhodného lesa, kdy finální zařazení ke klasifikační třídě y je získáno jako modus zařazení jednotlivých rozhodovacích stromů. Převzato z: [49].

4. Publikované postupy pro segmentaci a klasifikaci interních kalibračních tkání na základě CT dat

Tato sekce je přehledem publikací, v nichž se jejich autoři přímo zabývají segmentací a klasifikací paraspinálního svalu a tukové tkáně na základě CT obrazových dat. Vybrané publikované postupy jsou rozděleny do dvou sekcí, a to pro každou tkáň zvlášť, přičemž každá část obsahuje chronologický přehled publikací a stručný popis použité metodiky. Přičemž další možné v praxi používané postupy jsou uvedeny v sekci týkající se výpočtu BMD na základě interních kalibračních tkání, kde je popsána autory používaná metodika.

4.1 Publikace – paraspinální sval

Segmentace paraspinálního svalu je náročnou úlohou, a to z důvodu velkého rozptýlu Hounsfieldových jednotek v rámci této tkáně, přičemž konkrétní CT čísla jsou závislá na věku a zdravotním stavu daného pacienta [12]. Paraspinální svalstvo je konkrétně tvořeno skupinou 3 svalů a je zodpovědné za pohyby páteře. Je lokalizováno podélně po celé délce páteře kolem páteřního kanálu, od lebky až po pánev. [50]

WEI, Yong (2014)

Autoři tohoto článku využili pro segmentaci páteřního svalstva algoritmus fuzzy k-means jehož vstupem byla šedotónová prostorová mapa (GSM – z anglického „Gray Space Map“), která kombinuje prostorovou a jasovou informaci pro každý voxel. Semi – automatický proces vytváření této mapy je založen na modifikované metodě růstu oblastí definované v rámci tohoto zdroje: [51]. Hlavním předpokladem je, že voxely v rámci oblasti zájmu nemají pouze podobné jasové hodnoty, ale jsou mezi sebou i propojené. V procesu inicializace je uživatelem vybrán bod náležící do oblasti zájmu a je vytvořena nulová matice o rozměru vstupního obrazu, přičemž v každé iteraci dojde na dané pozici, kde voxel ve vstupním obraze vyhovuje podmínkám, k inkrementaci hodnoty o 1. Těmito podmínkami jsou: (1) rozdíl jasové hodnoty daného bodu a výchozího bodu je menší nebo roven definované hodnotě T, (2) daný pixel náleží do struktury, která překrývá výchozí bod. Postup tohoto algoritmu v rámci jedné iterace je vyjádřen následujícími rovnicemi [44]:

$$GSM(i, j) = \sum_{T=0}^{I_{max}} g(i, j, T), \quad (4-1)$$

$$g(i, j, T) = \begin{cases} 1, & \text{pokud } (i, j) \in R_T \wedge |I(i, j) - I(\text{seed}_x, \text{seed}_y)| \leq T, \\ 0 & \end{cases} \quad (4-2)$$

kde $GSM(i, j)$ je hodnota GSM na dané pozici, přičemž pro danou pozici dochází k sumaci výsledků z předchozích iterací, $I(i, j)$ je jasová hodnota voxelu vstupního obrazu na souřadnicích i, j , T je prahová hodnota difference, která je v první iteraci rovna nule (hledáme pouze totožné voxely) a v každé iteraci roste až po maximální možnou hodnotu (rozdíl maximální a minimální jasové hodnoty obrazu), R_T je oblast překrývající výchozí bod ($\text{seed}_x, \text{seed}_y$) v rámci dané hodnoty T . Takhle získaná GSM je následně normalizována, přičemž voxely spojené s výchozím bodem odpovídají vyšším hodnotám (oblast paraspinálního svalu je diferencovaná od okolních tkání), a použita jako vstup pro shlukovací algoritmus fuzzy k-means. [44]

WEI, Yong (2015)

V rámci tohoto článku je autory navržen algoritmus založený na použití modelu (atlasu) za účelem segmentace paraspinálního svalu. Publikovanou metodu je možné rozdělit na tři dílčí na sebe navazující části: (1) registrace modelu, (2) lokální optimalizace kontury a (3) lokální deformace. V inicializační fázi byla autory vybrána reprezentativní data, v nichž byla provedena manuální segmentace paraspinálního svalu a páteře za účelem vytvoření prostorového modelu, který je autory nazýván atlas. V dalším kroku je provedena registrace vytvořeného atlasu páteřní oblasti se vstupními daty, a to s využitím algoritmu ICP (z anglického „Iterative Closest Point“), čímž je získána afinní transformační funkce T , která je následně použita pro transformaci (namapování) kontur paraspinálního svalu z atlasu na vstupní data. Afinní transformace získaná registrací páteřních oblastí není však dostatečně přesná pro namapování svalových struktur, a proto je nutné její zpřesnění. K němu je využita lokální optimalizace, v rámci níž dochází k iterativní deformaci lokální kontury. V poslední fázi je pro zpřesnění výsledné segmentace paraspinálního svalu použit algoritmus aktivních kontur, konkrétně GVF snake algoritmus definovaný [53], kde je autory jako vstup použita intenzitní prostorová mapa (ISM – z anglického „Intensity Space Map“) vytvořená z manuálně zvoleného bodu, s jejímž využitím by dle autorů měl být eliminován vliv interference okolních tkání. [52]

4.2 Publikace – tuková tkáň

Tukovou tkáň v okolí páteře lze rozdělit na podkožní tukovou tkáň, což je vrstva tuku ležící přímo pod pokožkou, a útrobní (viscerální) tukovou tkáň, jež obklopuje útrobní orgány. Je možné říci, že akumulace tuku v břišní oblasti úzce souvisí s obezitou a je

důležitým faktorem z hlediska risku kardiovaskulárních onemocnění [54]. Z hlediska medicíny už na tukovou tkáň není nahlíženo pouze na jako jednoduchý sklad energie, ale jako na aktivní orgán s důležitými metabolickými a imunitně regulačními funkcemi [55]. Segmentace tukové tkáně z CT dat se oproti segmentaci paraspinálního svalu může zdát relativně jednoduchou úlohou, a to z důvodu že tuková tkáň leží ve specifickém intervalu od -190 do -30 HU, jež ji odlišuje od okolních tkání. Problémem však je závislost daného intervalu na akvizičních parametrech [56].

YOSHIKUMI, Tohru (1999)

Autory publikovaný postup se týká měření obsahu tukové tkáně v břišní oblasti těla, přičemž použitou segmentaci lze považovat za semiautomatickou. V prvním kroku uživatel v daném CT snímku manuálně vyznačí konturu podkožního tuku, čímž dojde k definování oblasti této tkáně. Z té je následně vytvořen histogram, na jehož základě je získán rozsah HU jednotek pro segmentaci viscerální tukové tkáně, jež je definován jako průměrný útluh ± 2 směrodatné odchylky. Celkový obsah tukové tkáně je následně získán jako součet pixelů podkožního tuku a pixelů viscerálního tuku. Dle autorů jejich postup dosahuje výsledků srovnatelných s planimetrickou metodou, využívající globální prahování s intervalem (-190,-30) HU, jež je autory považována za zlatý standard. Připouštějí však, že interval Hounsfieldových jednotek definující tukovou tkáň je závislý na akvizičních parametrech, a tudíž jejich publikovaný postup je v praxi přesnější a lze jej považovat jako standardizovanou techniku. [56]

PEDNEKAR, Amol (2005)

V rámci tohoto článku publikovaná automatická metoda kombinuje intenzitní a texturní informaci spolu s lokální soudržností pro danou tkáň. Vlastní segmentaci autoři realizují na základě metody fuzzy propojenosti definované v [57], jež byla modifikována, aby umožňovala globální přístup. Výsledný segmentační postup je možné popsat jako hierarchický, multi-třídní, multi-příznakový, fuzzy afinitní přístup pro segmentaci tkání. Globální třídní afinita je počítána na základě Mahalanobisovy vzdálenosti pro daný obrazový prvek. Lokální fuzzy afinita mezi dvěma pixely je počítána na základě jejich prostorové blízkosti a podobnosti v rámci intenzity a texturních příznaků, k čemuž je opět použita Mahalanobisova vzdálenost. Přičemž kombinace texturních příznaků s největší diskriminační silou je autory určena v rámci trénovací fáze, a to na základě Fisherova diskriminačního kritéria. Konkrétně jsou v rámci této fáze počítány Lawsovy a Gaborovy texturní příznaky, přičemž autoři určili, že Lawsovy příznaky dosahují větší diskriminační síly. V rámci trénovací fáze je autory také vytvořen tvarový model

podkožní tukové tkáně, který je následně použit pro inicializaci semínka (výchozího bodu), jež je potřebné pro vlastní segmentační proces. [54]

ROMERO, Daniel (2006)

Autory publikovaný postup pro kvantifikaci a diferenciaci podkožní a viscerální tukové tkáně lze rozdělit na blok segmentace, kde jsou získány binární masky těla a abdominální stěny, a blok vlastní kvantifikace tukové tkáně. Masky těla jsou získány na základě prahování, kdy hodnota prahu byla autory heuristicky odvozena. V následujícím kroku je hledána hranice břišní dutiny za účelem vytvoření vnitřní masky. Ze získané masky těla je vytvořena nová oblast zájmu, která je rozdělena na šest dílčích částí, v rámci nichž je hledána zmiňovaná hranice, přičemž hraniční pixely musí splňovat tato kritéria: (1) musí ležet v intervalu $(-20, 100)$ HU, (2) jejich vzdálenost od vnější hranice musí být větší než autory definovaná hodnota a (3) musí ležet v určité vzdálenosti od hraničního pixelu určeného v předchozím kroku. S využitím takto získaných masek jsou pomocí prahování hledány pixely odpovídající tukové tkáni, přičemž tyto pixely musí ležet v intervalu $(-190, -30)$ HU. [55]

ZHAO, Binsheng (2006)

Autoři tohoto článku přišli s další plně automatickou metodou pro kvantifikaci viscerálního tuku a podkožního tuku na základě CT dat abdominální a pánevní oblasti, jež je v určitých ohledech podobná předchozí popisované metodě. Publikovaný algoritmus automaticky identifikuje tělesný perimetr a hranici oddělující podkožní a viscerální tuk. Prvním krokem tohoto algoritmu je oddělení oblasti těla od pozadí na základě prostého prahování, kdy jako prahová hodnota je vzat průběh intenzit daného řezu. Na takto vysegmentovanou oblast jsou následně aplikovány morfologické operace, čímž je získána kontura těla. Z té jsou následně vedeny pomyslné paprsky, mezi s sebou svírající úhel 3° , do středu vysegmentované oblasti, v rámci nichž jsou analyzovány jasové profily za účelem segmentace oblasti podkožního tuku. Tímto postupem je také získána hranice mezi podkožním tukem a tělesnou dutinou, jež však může být zkreslena patologiemi jako např. kalcifikace, a proto v dalším kroku dojde k jejímu zpřesnění. S využitím získané vnitřní hranice a kontury těla dojde k segmentaci tukové tkáně, ležící v rámci těchto hranic, na základě předpokladu, že pixely odpovídající této tkáni náleží do intervalu $(-190, -30)$ HU. [58]

5. Statistické metody použité pro redukci vektoru příznaků a redukce šumu metodou NLM

5.1 Korelační analýza

V převážné většině případů existují mezi proměnnými (příznaky) korelační vztahy, což znamená, že se navzájem vysvětlují, a tudíž není třeba všech příznaků (dimenzí vstupních dat) pro popis kompletní informace v datech obsažené [59]. Všechny statistické metody náležící do sekce ordinační analýzy (vícerozměrné statistické metody zabývající se redukcí dimenzionality vstupních dat) využívají principu identifikace korelovaných příznaků a jejich sloučení do souhrnných nových příznaků, jež zastupují několik příznaků ze vstupního souboru [59]. Platí, že pokud mezi příznaky vstupního souboru neexistují korelační vztahy, tak nemá smysl provádět redukci (zjednodušení) takového souboru [59]. Korelační analýza je statistickou metodou, která je využívána pro vyhodnocení stupně podobnosti mezi analyzovanými proměnnými (příznaky). Tato podobnost je vyjádřena pomocí korelačních koeficientů, které náleží do intervalu od -1 do 1. Pokud tento koeficient nabývá hodnotu blízkou 1 popřípadě -1, znamená to, že dané příznaky spolu silně korelují. V praxi je možné provést výpočet Pearsonova korelačního koeficientu, popřípadě Spearmanova korelačního koeficientu, který je neparametrický (pracuje s pořadím hodnot), a proto je na rozdíl od Pearsonova korelačního koeficientu odolný vůči odlehlým hodnotám [37]. Tento vztah mezi proměnnými je možné posoudit i graficky např. vyhodnocením závislosti proměnných v bodovém grafu, přičemž posouzení podobnosti tímto způsobem je velmi subjektivní. [22] [37] [59] [60]

5.2 Analýza hlavních komponent

Analýza hlavních komponent nebo také PCA (z anglického „Principal component analysis“) je statistickou metodou, která patří do metod ordinační analýzy. Cílem PCA je analýza variability a vztahů mezi spojitými (popřípadě diskrétními) proměnnými, přičemž je usilováno o snížení počtu těchto proměnných (snížení dimenze vstupních dat) bez významné ztráty informací. Je tedy snaha stanovit dimenze zahrnující větší podíl variability, než připadá na původní proměnné [59]. Metoda je tedy vhodná pro hledání neredundantních proměnných, které mohou být následně použity jako vstup dalších analýz. Konkrétně dochází k rozložení korelovaných proměnných (matice dat) do hlavních komponent (faktorových os), přičemž každé komponentě je přiřazena hodnota, která odpovídá vyčerpané variabilitě touto komponentou. Jedná se o lineární kombinace původních proměnných, které vytváří dané komponenty, přičemž první hlavní

komponenta vyčerpává nejvíce z celkové vyčerpané variability. Platí, že v případě, kdy vstupní data neobsahují redundantní proměnné, dosahuje vyčerpaná variabilita první faktorovou osou nízké hodnoty. To souvisí s tím, že redundantní proměnné zvyšují vyčerpanou variabilitu faktorové osy, s níž jsou spjaty. Každá faktorová osa obsahuje všechny vstupní proměnné, ale každá je násobená jiným koeficientem. Tento koeficient udává míru, jakou měrou vstup přispívá do vyčerpané variability dané komponenty. Proměnné, které z tohoto hlediska nejsou relevantní, přispívají malou měrou k celkové vyčerpané variabilitě. [22] [59] [61] [62]

Výpočet PCA je založen na korelačních nebo kovariančních maticích, přičemž jsou počítány vlastní vektory a čísla daného typu matice. Volba typu matice vychází ze vstupních dat. Pokud se jedná o data, která nejsou ve stejných jednotkách, je nutné použít korelační matici. Kovarianční matici je možné použít, pokud se jedná o data, která mají stejnou jednotku. Přičemž platí, že korelace je vlastně kovariance standardizovaná na variabilitu dat, tedy kovariance na standardizovaných datech je korelace [59]. Výstupem vlastní analýzy jsou již zmíněné vlastní vektory (eigenvector) a vlastní čísla (eigenvalues), přičemž vlastní vektory definují směr nových faktorových os v prostoru původních proměnných a vlastní čísla jsou ve vazbě na variabilitu vyčerpanou vytvářenými faktorovými osami [59]. Platí, že faktorová osa je přímo definována vlastními vektory, které musí být ortogonální, čímž se PCA odlišuje např. od kanonické analýzy. V dalším kroku je nutné identifikovat optimální počet faktorových os, což je možné na základě těchto kritérií: Kaiser Guttmanovo kritérium, Scree plot či na základě Sheppard diagramu. V případě Kaiser Guttmanova kritéria probíhá výběr komponent, které mají vlastní číslo větší jak jedna, popřípadě větší jak průměrné eigenvalue (v případě kovarianční matice). V rámci Scree plotu je zobrazena vyčerpaná variabilita jednotlivými faktorovými osami a je hledán zlom mezi vztahem počtu os a právě vyčerpané variability. Na základě těchto kritérií dochází ke snížení počtu dimenzí původních dat, přičemž optimální počet dimenzí jsou dvě, popřípadě tři, a to kvůli možnému zobrazení. [22] [59] [61] [62]

5.3 Diskriminační analýza

Diskriminační analýza patří stejně jako analýza hlavních komponent mezi statistické metody náležící do ordinační analýzy. Podle typu vztahu mezi proměnnými je možné odlišit diskriminační analýzu lineární a kvadratickou. U lineární analýzy platí předpoklad o lineární závislosti mezi proměnnými, je tedy možné jejich oddělení podél přímky ve vícerozměrném prostoru. Podle účelu je možné rozlišit kanonickou diskriminační analýzu a klasifikační diskriminační analýzu. Kanonická analýza se provádí za účelem

identifikace proměnných důležitých pro diskriminaci. Cílem této metody je nalezení proměnných (příznaků), které dokáží nejlépe diskriminovat mezi předem zvolenými skupinami (kategoriemi – např. tkáně). Je tedy nutné předem definovat kategorie, které mají příznaky rozlišit. Oproti tomu u klasifikační diskriminační analýzy je snaha o vlastní klasifikaci vstupních neznámých objektů do definovaných skupin. [22] [37] [63]

Vlastní kanonická analýza probíhá tak, že prvním kroku se testují významnosti rozdílů v hodnocených proměnných mezi danými kategoriemi objektů. Následně probíhá vlastní diskriminační funkce, kdy na základě lineární regrese je hledána kombinace proměnných, které nejlépe odlišují mezi jednotlivými kategoriemi. Prakticky dochází k vybírání proměnných na základě jejich diskriminační síly (schopnosti odlišit) a proměnné s velkou diskriminační silou jsou zařazovány do modelu. V případě, že se vyskytnou dvě korelované proměnné se stejnou diskriminační silou, je do výsledného modelu zařazena pouze jedna z nich. Tuto eliminaci vstupů je možné provádět dopředně i zpětně. U dopředné eliminace jsou proměnné do modelu postupně přidávány, kdy v prvním kroku je vybrán vstup s největším významem pro diskriminaci mezi skupinami. Postupně jsou k němu přidávány další proměnné, dokud není dosaženo stavu, kdy již nedochází k vylepšení diskriminační schopnosti modelu. U zpětné eliminace probíhá postup obdobně, akorát v prvním kroku jsou do modelu zařazeny všechny vstupní proměnné a postupně jsou ubírány proměnné s nejmenší diskriminační schopností. [22] [37] [63]

5.4 Redukce šumu algoritmem Non-Local means

Redukce šumu je rozhodujícím krokem pro zlepšení kvality obrazu a zvýšení funkčnosti všech úloh nutných pro kvantitativní analýzu obrazu [64]. Velkým problémem je však snižování úrovně šumu v obraze, zatímco integrita relevantní obrazové informace zůstane zachována [64]. NLM filtr (z anglického „Non-Local Means“) byl představen Buadesem et al. [65] v roce 2005 a byl původně určen pro 2D obrazová data. Tento filtr je založen na redundanci informace v analyzovaném obraze, která je využita pro redukci šumu. Hlavní myšlenkou je, že každá přirozená obrazová data obsahují redundanci a že každý voxel obrazu má k sobě podobné voxely, jež nemusí být lokalizovány v jeho blízkém prostorovém okolí (mohou být kdekoliv v rámci daného obrazu) [64], což platí např. u periodických či texturních obrazů. Většina metod určených pro redukci šumu je založena na zisku intenzitní hodnoty daného voxelu jako určitém průměru intenzitních hodnot voxelů lokalizovaných v jeho sousedním okolí. Oproti tomu v rámci filtrace NLM je hodnota daného voxelu získána jako váhovaný průměr všech voxelů v daném obraze, přičemž váha pro daný voxel je závislá na podobnosti s okolím analyzovaného voxelu

[65]. Celý postup může být matematicky popsán následujícím způsobem, mějme diskrétní zašuměný obraz v , odhadnutá hodnota tohoto obrazu $NL[v](i)$ pro pixel i , je vypočtena jako [65]:

$$NL[v](i) = \sum_{j \in I} w(i, j) v(j), \quad (5-1)$$

kde $v(j)$ je hodnota pixelu j v zašuměném obraze, $w(i, j)$ váha závisující na podobnosti pixelů i a j , přičemž platí, že $0 \leq w(i, j) \leq 1$ a $\sum_{j \in I} w(i, j) = 1$. Podobnost mezi dvěma pixely i a j závisí na podobnosti intenzitních vektorů $v(N_i)$ a $v(N_j)$, jež odpovídají čtvercovým okolím o definované velikosti kolem pixelů i a j . Tato podobnost je vypočtena jako klesající funkce váhované Euklidovské vzdálenosti $\|v(N_i) - v(N_j)\|_{2,a}^2$, kde $a > 0$ je směrodatná odchylka Gausovského jádra filtru. Přičemž vlastní váhy jsou definovány vztahem [65]:

$$w(i, j) = \frac{1}{Z(i)} e^{-\frac{\|v(N_i) - v(N_j)\|_{2,a}^2}{h^2}}, \quad (5-2)$$

kde $Z(i)$ je normalizační konstanta definovaná [65]:

$$Z(i) = \sum_j e^{-\frac{\|v(N_i) - v(N_j)\|_{2,a}^2}{h^2}}, \quad (5-3)$$

kde h odpovídá stupni filtrace (dá se tedy brát jako vyhlazovací parametr). Tento parametr kontroluje pokles definované exponenciální funkce ve vztahu (5-2), a tudíž kontroluje pokles vah jako funkce Euklidovských vzdáleností. Je patrné, že pixely s podobnými hodnotami intenzity v rámci definovaných okolí mají vyšší hodnoty vah, a tudíž vyšší význam v rámci průměrování, a tedy celkové filtrace. Celý postup shrnut do jedné rovnice, definující výpočet filtrované hodnoty $NL[v](i)$ pro pixel i [65]:


$$NL[v](i) = \sum_{j \in I} \frac{1}{\sum_j e^{-\frac{\|v(N_i) - v(N_j)\|_{2,a}^2}{h^2}}} e^{-\frac{\|v(N_i) - v(N_j)\|_{2,a}^2}{h^2}} v(j). \quad (5-4)$$

6. Vlastní metodologické řešení


Realizaci praktické části této diplomové práce lze rozdělit do pěti dílčích na sebe navazujících kroků. V první fázi byla vytvořena databáze patientských dat, na níž bylo v následujícím kroku provedeno manuální označování tkání zájmu. Tím byla vytvořena databáze manuálně označených dat, jež byla využita jako zlatý standard. V rámci další fáze bylo provedeno testování funkčnosti zvolených segmentačních a klasifikačních přístupů. Těmi konkrétně byly globální prahování, texturní analýza s klasifikací texturních příznaků algoritmem k-means a klasifikace algoritmem náhodného lesa. Celá realizace byla konzultována se spolupracujícím lékařem, s nímž byly dále navrženy možné modifikace, jež byly v další fázi testovány. V posledním kroku bylo provedeno statistické vyhodnocení funkčnosti jednotlivých testovaných přístupů a přínosu navržených modifikací. Cílem celého testování bylo zvolit, na základě dosažených výsledků a lékařského zhodnocení, přístup, jež by byl následně v praxi používán pro automatickou segmentaci a klasifikaci interních kalibračních tkání v rámci výpočtu minerální denzity obratlů. Následující části této práce obsahují popis jednotlivých fází vlastní realizace, přičemž vlastní řešení bylo realizováno v programovacím prostředí Matlab®.

6.1 Vytvoření databáze patientských dat

Do vytvořené databáze byla zahrnuta anonymizovaná patientská 3D tomografická data s vysokým rozlišením ve formátu DICOM, jež byla nasnímana na CT systému Philips – Healthcare Brilliance iCT skener s 256-řadým detektorem a s akvizičními parametry: anodové napětí 140 KV, anodový proud 232 mA a celková expozice 400 mAs. Konkrétně databáze obsahovala obrazová data lumbální části páteře pro 12 pacientů, z toho 5 pacientů podstoupilo CT vyšetření se zavedenou kontrastní látkou a 7 pacientů podstoupilo nativní vyšetření. Celkově bylo v databázi obsaženo 30 nativních a 24 kontrastních obratlů. Z původních obrazových dat (Obrázek 6-1) byly vytvořeny výřezy (Obrázek 6-2) kolem známe pozice centroidů jednotlivých obratlů, tak aby ve výsledných výřezech byla obsažena dostatečně velká oblast tkání zájmů, ale zároveň došlo k výraznému zmenšení velikosti, a to z důvodu snížení časové náročnosti realizované obrazové analýzy. Databáze byla dále rozdělena na učební a testovací část. Přičemž učební část obsahovala obrazová data 5 nativních a 3 kontrastních pacientů a do testovací databáze bylo zařazeno po dvou nativních a dvou kontrastních pacientech. Zařazení obratlů do jednotlivých částí této databáze bylo provedeno náhodně. Na takto vytvořené databázi byla následně provedena realizace a testování zvolených segmentačních a klasifikačních přístupů.




Obrázek 6-1: Původní data – řez nativním L2 obrátem daného pacienta.




Obrázek 6-2: Vstupní data pro testované metody – výřez z původních dat (řez nativním obrátem L2 daného pacienta).

6.2 Manuální označování interních kalibračních tkání

Na vytvořené patientské databázi bylo provedeno manuální voxelové označování oblastí výskytu tkání zájmu (Obrázek 6-4). Konkrétně bylo vždy označeno 5 řezů pro daný obratel, celkově se tedy jednalo o 270 označených řezů. Jednalo se však pouze o masky určující nejpravděpodobnější výskyt tkání zájmů. Pro dosažení masek s voxelovou přesností pro obě tkáně zájmu došlo k následnému zpřesnění manuálně označených masek. Přičemž správnost vytvořených masek byla lékařsky ověřena.




Obrázek 6-3: Vstupní data pro testované metody – výřez z původních dat (řez nativním obrátem L2 daného pacienta).




*Obrázek 6-4: Překrytí označených dat a vstupních dat pro testované metody – výřez z původních dat (řez nativním obrátem L2 daného pacienta).
Legenda: šedá barva – paraspinální sval, bílá barva – podkožní tuk.*

Toto zpřesnění bylo realizováno na základě analýzy histogramů oblastí výskytu tkání zájmu, a to po jednotlivých řezech. V rámci daného tomografického řezu byly s využitím odpovídající označené masky vymezeny pixely odpovídající oblasti výskytu dané kalibrační tkáně, jež byly dále analyzovány. Na základě vytvořeného histogramu byl pro danou tkáň a daný řez stanoven specifický interval jasových hodnot za účelem eliminace odlehlých jasových hodnot. Tyto intervaly byly stanoveny s využitím hodnoty modu a směrodatné odchylky (std) dané tkáně, kdy pro tukovou tkáň byl konkrétně stanoven interval ($\text{modus} - 2\text{std}$, $\text{modus} + 2\text{std}$) a pro paraspinální sval ($\text{modus} - \text{std}$, $\text{modus} + 2\text{std}$). Je patrné, že pro paraspinální sval byl specifický interval výrazně zleva omezen, a to z důvodu eliminace jasových hodnot odpovídajících tukové tkáni prorůstající daným svalstvem. Pro názornost jsou pro konkrétní řez v rámci obrázků (Obrázek 6-5 a Obrázek 6-6) zobrazeny histogramy interních kalibračních tkání s vyznačenými stanovenými specifickými intervaly jasových hodnot. Zpřesněné masky byly následně získány tak, že z původních masek byly odstraněny pixely, jež v rámci daných tomografických řezů ležely pro danou tkáň mimo její stanovený specifický interval pro daný řez.




Obrázek 6-5: Histogram jasových hodnot označené oblasti podkožní tukové tkáně pro daný řez s vyznačeným specifickým intervalem.




Obrázek 6-6: Histogram jasových hodnot označené oblasti paraspinálního svalu pro daný řez s vyznačeným specifickým intervalem.

Zpřesněné masky (Obrázek 6-7) byly dále dilatovány (Obrázek 6-8), za účelem uzavření a propojení vzniklých oblastí zpřesněných masek, a konzultovány s lékařem. Ten pro další fáze této práce zvolil pouze zpřesněné masky (Obrázek 6-7) bez dilatace, které podle něj dosahovaly dostatečné voxelové přesnosti pro obě tkáně zájmu.



Obrázek 6-7: Překrytí zpřesněné masky a odpovídajícího výřezu z tomografického řezu (řez nativním obratlem L2 daného pacienta).

Legenda: šedá barva – paraspinální sval, bílá barva – podkožní tuk.




Obrázek 6-8: Překrytí zpřesněné masky po dilataci a odpovídajícího výřezu z tomografického řezu (řez nativním obratlem L2 daného pacienta).

Legenda: šedá barva – paraspinální sval, bílá barva – podkožní tuk.


6.3 Testování zvolených segmentačních a klasifikačních přístupů

6.3.1 Globální prahování

V rámci testování tohoto přístupu bylo nutné stanovit pro dané akviziční parametry, s nimiž byla získána v databázi obsažená tomografická data, charakteristické intervaly CT hodnot (z hlediska analýzy daných obrazových dat jasové hodnoty) tkání zájmu, a to pro kontrastní a nativní data zvlášť. K tomu byla využita učební část patientské databáze a k ní odpovídající manuálně označená databáze interních kalibračních tkání. Charakteristické intervaly byly následně stanoveny na základě analýzy histogramu, kdy pro každou tkáň byly do výsledného grafu četností zahrnuty všechny voxely k této tkáni náležící z učební databáze. Výsledné specifické intervaly byly stanoveny s využitím hodnoty modu a směrodatné odchylky (std), kdy pro podkožní tukovou tkáň byl stanoven interval ($\text{modus} - 2\text{std}$, $\text{modus} + \text{std}$) a pro paraspinální sval ($\text{modus} - \text{std}$, $\text{modus} + 2\text{std}$), přičemž tyto intervaly byly stanoveny s ohledem na zamezení překryvu jasových hodnot těchto intervalů. Histogramy pro obě tkáně zájmu na základě nativních dat jsou uvedeny v rámci obrázků (Obrázek 6-9 a Obrázek 6-10), kde jsou vyznačeny i určené specifické intervaly, jež jsou konkrétně uvedeny v rámci tabulky (Tabulka 6-1).



Obrázek 6-9: Histogram jasových hodnot podkožní tukové tkáně na základě nativních dat s vyznačeným specifickým intervalem.



Obrázek 6-10: Histogram jasových hodnot paraspinálního svalu na základě nativních dat s vyznačeným specifickým intervalem.

Tabulka 6-1: Přehled stanovených specifických jasových intervalů použitých v rámci globálního prahování interních kalibračních tkání.

	Paraspinální sval		Podkožní tuková tkáň	
	Nativní data	Kontrastní data	Nativní data	Kontrastní data
Specifický interval [HU]	(-35; 163)	(-29; 190)	(-195; -45)	(-216; -30)

6.3.2 Texturní analýza s klasifikací algoritmem *k*-means

Vlastní realizaci testování texturní analýzy s klasifikací texturních příznaků algoritmem *k*-means pro segmentaci a klasifikaci interních kalibračních tkání lze rozdělit do tří dílčích, na sebe navazujících kroků. V první fázi proběhl výpočet vektoru texturních příznaků, jež byl v další fázi redukován o redundantní příznaky, s využitím korelační analýzy a analýzy hlavních komponent, a dále o nevýznamné příznaky z hlediska diskriminace tkání zájmu, s využitím dopředné lineární diskriminační analýzy. Takto redukováný vektor příznaků byl v závěrečné fázi klasifikován algoritmem *k*-means, kdy výsledné shluky odpovídající tkáním zájmu byly určeny s využitím Euklidovské vzdálenosti ve vícerozměrném prostoru a určených charakteristik pro tkáň zájmu.

6.3.2.1 Výpočet vektoru texturních příznaků

Vlastní vektor texturních příznaků byl vypočítán na základě metod texturní analýzy popsanych v předchozí sekci této práce. Konkrétně byly pro výpočet použity lokální statistické metody prvního i druhého řádu, lokální spektrální analýzy a mikrotextrní

analýzy, přičemž pro každý voxel bylo vypočteno 198 texturních příznaků (přehled počtů texturních příznaků počítaný na základě jednotlivých metod uveden v: Tabulka 6-2, kompletní seznam příznaků uveden v: Tabulka A-1). Konkrétně se jednalo o 3D texturní příznaky, jež byly vždy počítány z 3D okolí o definované velikosti. V následujících sekcích bude popsána realizace výpočtu texturních příznaků jednotlivými metodami.

Tabulka 6-2: Přehled počtů texturních příznaků počítaných na základě jednotlivých metod texturní analýzy.

	Počet texturních příznaků
Statistické metody I. řádu	7
Statistické metody II. řádu	27
Spektrální analýza	12
Mikrotexturní analýza	152

Statistické metody I. řádu

Na základě statistických metod prvního řádu bylo konkrétně vypočteno 7 příznaků, a to lokální průměr, lokální směrodatná odchylka, lokální průměrná absolutní odchylka, lokální rozptyl, lokální špičatost, lokální šikmost a lokální entropie. Přičemž Vlastní výpočet probíhal s využitím lokálních nelineárních 3D filtrů s velikostí masky $5 \times 5 \times 5$.

Statistické metody II. řádu

Výpočet texturních příznaků na základě statistických metod druhého řádu je založen na vytváření matic současného výskytu a délky běhů, z nichž jsou následně počítány texturní příznaky. Přičemž tento výpočet probíhal vždy pro 3D oblast vymezenou krychlí o hraně 5 voxelů. Pro vytváření zmiňovaných matic a následný výpočet texturních příznaků byly použity funkce popsané v následující kapitole, kdy celkově bylo vypočteno 27 3D texturních příznaků (16 příznaků na základě matic současného výskytu a 11 příznaků na základě matic délky běhů).


V rámci funkcí pro vytváření obou typů matic byla možná různá nastavení, kdy konkrétně pro matice současného výskytu bylo možné nastavit v našem případě 4 vzdálenosti (1,2,3,4) vůči výchozímu voxelu a 13 různých směrů. U matic délky běhů

bylo v rámci použité funkce možné nastavit 9 různých směrů. Optimální nastavení pro výpočet obou typů matic bylo určeno na základě korelační analýzy a analýzy hlavních komponent (teoreticky popsány v předchozí sekci této práce), kdy proběhl výpočet texturních příznaků pro všechna možná nastavení a následně bylo hledáno to nastavení, jež vyčerpávalo největší podíl z vyčerpané variability. Toto hledání bylo provedeno na základě obrazových dat náhodně zvoleného obrátle. Před vlastní analýzou byl vypočtený vektor texturních příznaků normalizován (min-max normalizace definována vztahem: (6-1)) z důvodu převedení příznaků na stejné měřítko. V rámci korelační analýzy byl počítán Pearsonův korelační koeficient a byly hledány atributy, jež spolu v absolutní hodnotě korelovaly s koeficientem vyšším než 0,85. Po redukci korelovaných atributů, byla provedena analýza hlavních komponent, v rámci níž proběhl výpočet kovarianční matice a optimální počet faktorových os byl volen na základě Kaiser-Gutmanova kritéria a analýzy Scree-plotu. Atribut vyčerpávající nejvíce z vyčerpané variability byl následně určen na základě biplotu korelací.

Nejprve byla hledána optimální hodnota parametru vzdálenosti, pro níž byl následně určen optimální směr. Na základě korelační analýzy vzdáleností se zahrnutými všemi směry bylo u matic současného výskytu, vypočtených na základě nativních dat, zjištěno, že spolu silně korelovaly vzdálenost 1 se vzdáleností 2, ta dále korelovala ještě se vzdáleností 3, přičemž vzdálenost 4 silně nekorelovala se žádnou jinou vzdáleností (viz. Tabulka 6-3). Do další fáze hledání optimálního nastavení pro matice současného výskytu na základě nativních dat byly tedy zvoleny vzdálenosti 2 a 4. Ty byly dále podrobeny analýze hlavních komponent, přičemž pro vykreslení biplotu korelací (Obrázek 6-11) byly použity obě faktorové osy (vyčerpávaly 100 % z vyčerpané variability). Bylo zjištěno, že s první faktorovou osu (vyčerpávala 85,78 % z vyčerpané variability) nejvíce korelovala vzdálenost 2, a proto byla zvolena jako optimální vzdálenost pro výpočet matic současného výskytu. Optimální směr pro tento typ matice byl určen obdobným způsobem, kdy bylo konkrétně zjištěno, že největší podíl vyčerpané variability vyčerpávaly texturní příznaky, jež byly vypočteny pro směr 0 ° (vodorovně). Takto bylo hledáno i optimální nastavení pro matice současného výskytu na základě kontrastních dat.

Tabulka 6-3: Pearsonovy korelační koeficienty vzdáleností u matic současného výskytu.

1	0.89	0.75	0.57
0.89	1	0.88	0.67
0.75	0.88	1	0.8
0.57	0.67	0.8	1



Obrázek 6-11: Biplot korelací prvních dvou hlavních komponent pro vzdálenosti 2 a 4 u matic současného výskytu na základě nativních dat.

V rámci hledání optimálního nastavení pro matice délky běhů bylo zjištěno, že spolu silně korelovaly všechny směry (viz. Tabulka 6-4), a to pro nativní i kontrastní data. Na základě čehož lze usuzovat malý význam směrovosti textury v analyzovaném obraze obsažené. Zjištěné optimální nastavení pro oba typy matic a pro nativní a kontrastní data je uvedeno v rámci tabulky (Tabulka 6-5).

Tabulka 6-4: Pearsonovy korelační koeficienty směrů u matic délky běhů.

1	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99
0.99	1	1	1	0.98	1	1	1	1
0.99	1	1	1	0.99	1	1	1	1
0.99	1	1	1	0.98	1	1	1	1
0.99	0.98	0.99	0.98	1	0.98	0.98	0.99	0.99
0.99	1	1	1	0.98	1	1	1	1
0.99	1	1	1	0.98	1	1	1	1
0.99	1	1	1	0.99	1	1	1	1
0.99	1	1	1	0.99	1	1	1	1

Tabulka 6-5: Nalezené optimální nastavení pro matice současného výskytu a matice délky běhů.

	Nativní data	Kontrastní data
Matice současného výskytu	vzdálenost: 2; směr: 0° (vodorovně)	vzdálenost: 2; směr: 90° v ose z (přímo vzhůru)
Matice délky běhů	směr: 0° (vodorovně)	směr: 0° (vodorovně)

Lokální spektrální analýza

Výpočet texturních příznaků s využitím lokální spektrální analýzy byl realizován na základě diskretní Fourierovy transformace. Přičemž pro výpočet spektrálních koeficientů byla vždy brána 3D oblast ze vstupních obrazových dat ohraničená krychlí o hraně 9 voxelů (pro korektní výsledky bylo nutné zahrnout větší počet voxelů pro výpočet texturních příznaků oproti jiným texturním metodám). Vlastními vypočtenými texturními příznaky byly parametrický výkon a relativní parametrický výkon, přičemž tyto příznaky bylo vždy počítány v rámci definovaných frekvenčních pásmech. Tato pásma byla vymezena pomocí vytvořených binárních masek, kdy konkrétně bylo vytvořeno šest masek (pro šest frekvenčních pásem), přičemž šířka pásem se zvětšovala od nejnižších prostorových frekvencí po nejvyšší (pásmo nejvyšších prostorových frekvencí bylo nejširší). Parametrický výkon byl počítán jako druhá mocnina amplitudového spektra (absolutní hodnota spektra) pro dané frekvenční pásmo a relativní parametrický výkon byl počítán jako průměr amplitudového spektra v daném frekvenčním pásmu dělený průměrem amplitudového spektra v okolních pásmech. Celkově bylo na základě spektrální analýzy vypočteno 12 3D texturních příznaků.

Mikrotexturní analýza

Texturní příznaky na základě mikrotexturní analýzy byly získány konvolucí obrazových dat s Lawsovy maskami. Konkrétně byly využity 3D masky vytvořené z tříprvkových (27 masek) i pětiprvkových (125 masek) vektorů, kdy se celkově jednalo o 152 masek. Na základě konvoluce vstupních obrazových dat s těmito vytvořenými maskami byly získány parametrické obrazy reprezentující příznaky související s texturní směrovostí.

6.3.2.2 Redukce vektoru texturních příznaků

Provedenou redukci vektoru texturních příznaků lze rozdělit do na sebe navazujících kroků, přičemž tato redukce byla provedena pro kontrastní a nativní data zvlášť. Nejprve

byl daný vektor redukován o redundantní příznaky (tj. korelované příznaky či příznaky vyčerpávající nízký podíl z celkové vyčerpané variability), identifikovány na základě korelační analýzy a analýzy hlavních komponent, a následně byl takto redukovaný vektor texturních příznaků podroben kanonické diskriminační analýze za účelem identifikace příznaků relevantních pro diskriminaci mezi tkáněmi zájmu. Pro realizaci této redukce byly vypočteny 3D texturní příznaky obrazových dat náhodně zvoleného obrátle, přičemž tyto příznaky byly již vypočteny s optimálním nastavením pro statistické metody II. řádu (uvedeno v: Tabulka 6-5). Před vlastní redukcí byl vypočtený vektor podroben normalizaci (min-max normalizace definována vztahem: (6-1) [67], jež je vhodná i v případech, kdy proměnné nemají normální rozdělení nebo obsahují odlehlé hodnoty [67]) za účelem převedení příznaků na stejné měřítko.

$$y_i = \frac{x_i - \min(x)}{\max(x) - \min(x)}, \quad (6-1)$$


kde y_i je i -tý prvek normalizovaného vektoru, x_i je i -tý prvek vstupního vektoru a x odpovídá vstupnímu vektoru.

V rámci realizace první fáze redukce normalizovaného vektoru byly nejprve analyzovány příznaky z každé skupiny (tj. statistické metody I. řádu, statistické metod II. řádu, spektrální analýza a mikrotexturní analýza) zvlášť a po této prvotní redukcí proběhla další redukce zbývajících příznaků dohromady. V rámci korelační analýzy byl vektor redukován o korelované příznaky. Kdy byl počítán Pearsonův korelační koeficient a byly hledány atributy, jež spolu v absolutní hodnotě korelovaly s daným koeficientem vyšším než 0,85 (pro názornost jsou v tabulce (Tabulka 6-6) uvedeny tyto koeficienty pro texturní příznaky na základě statistických metod prvního řádu (na základě nativních dat), kdy konkrétně byly vyřazeny příznaky 3 (lokální průměrná absolutní odchylka) a 4 (lokální rozptyl)). Následně byly nekorelované příznaky podrobeny analýze hlavních komponent, v rámci níž byl ideální počet faktorových os volen na základě Kaiser-Gutmanova kritéria a analýzy Scree plotu (v případě redukce nekorelovaného vektoru texturních příznaků na základě statistických metod I. řádu zvoleny první dvě faktorové osy, jež společně vyčerpávaly 92,1 % z celkové vyčerpané variability) a následná identifikace příznaků (vyčerpávajících nejvyšší podíl z vyčerpané variability) byla provedena na základě analýzy vykresleného biplotu korelací (viz. Obrázek 6-12, na základě jehož analýzy byly v daném případě zvoleny příznaky: 1 (lokální průměr), 2 (lokální směrodatná odchylka) a 7 (lokální entropie), jež nejvíce korelovaly s danými faktorovými osami). Seznam neredundantních příznaků identifikovaný popsáním způsobem je uveden v rámci tabulky (Tabulka 6-7), přičemž je patrné, že z původních 198 3D texturních příznaků pro voxel zůstalo v případě nativních dat pouze 6 příznaků a v případě dat kontrastních 7 příznaků.

Dále je patrné, že do výsledného redukovaného vektoru nebyl zařazen žádný příznak z mikrotexturní analýzy. Bylo totiž zjištěno, že hlavní význam z hlediska vyčerpané variability měl pouze příznak získaný konvolucí první maskou (odpovídající lokálnímu váhovanému průměru). Přičemž tento příznak byl silně korelovaný s lokálním průměrem (na základě statistických metod I. řádu), a tudíž byl vyřazen.

Tabulka 6-6: Pearsonovy korelační koeficienty 3D texturních příznaků na základě statistických metod prvního řádu (nativní data).

1	-0.04	-0.04	-0.1	-0.08	-0.21	0.26
-0.04	1	1	0.95	-0.13	0.16	0.7
-0.04	1	1	0.96	-0.17	0.14	0.68
-0.05	0.95	0.96	1	-0.14	0.13	0.5
-0.08	-0.13	-0.17	-0.1	1	0.35	-0.2
-0.21	0.16	0.14	0.13	0.35	1	0.04
0.26	0.7	0.68	0.5	-0.2	0.04	1



Obrázek 6-12: Biplot korelací prvních dvou hlavních komponent pro nekorelované 3D texturní příznaky na základě statistických metod I. řádu pro nativní data.

Tabulka 6-7: Přehled neredundantních 3D texturních příznaků z jednotlivých sekcí texturní analýzy pro nativní i kontrastní data.

	Nativní data	Kontrastní data
Statistické metody I. řádu	Lokální průměr, směrodatná odchylka a entropie	Lokální průměr, směrodatná odchylka a entropie
Statistické metody II. řádu	Suma průměrů a rozptyl	Suma průměrů, rozptyl a informační míra korelace
Spektrální analýza	Relativní parametrický výkon nízkých prostorových frekvencí	Relativní parametrický výkon nízkých prostorových frekvencí
Mikrotexturní analýza	-	-

Neredundantních příznaky (pro nativní a kontrastní data zvlášť) byly následně podrobeny dopředné lineární diskriminační analýze za účelem zmiňované identifikace příznaků s největší diskriminační silou pro diskriminaci mezi tkáněmi zájmu. Diskriminační modely byly vždy tvořeny na hladině významnosti 0,05 pro zařazení do modelu a na hladině významnosti 0,1 pro vyřazení příznaku z modelu. Přičemž bylo zjištěno, že v obou případech, byly jako první do diskriminačního modelu zařazeny příznaky ze statistických metod prvního řádu (konkrétně lokální průměr a lokální směrodatná odchylka), jež společně tvořily diskriminační model s parametry uvedenými v rámci: Tabulka 6-8 (model dosahoval chyby 17,4 % a vyčerpával 87,4 % z celkové variability). Zařazení další příznaků do výsledného modelu (parametry modelu uvedeny v rámci: Tabulka 6-9) nepřineslo výraznou změnou z hlediska sledovaných parametrů (snížení chyby diskriminace modelu pouze o 0,5 % a zvýšení celkové vyčerpané variability modelu o 0,7 %), na základě čehož lze usuzovat, že zmiňované dva příznaky ze statistických metod prvního řádu měly největší význam z hlediska diskriminace (měly největší diskriminační sílu).

Přičemž bylo otestováno, že v případě použití všech příznaků zařazených do výsledného modelu bylo na základě segmentace s využitím shlukové analýzy (postup popsán v následující sekci této práce) dosaženo špatných výsledků (viz. Obrázek 6-13), kdy je zřejmá značná přesegmentovanost výstupu. Oproti tomu v případě použití pouze příznaků s největší diskriminační silou bylo dosaženo relativně dobrých výsledků, kdy je

patrné, že již došlo úspěšnému odlišení tkání zájmu (viz. Obrázek 6-14). Z tohoto důvodu byly pouze tyto dva příznaky využity pro následnou klasifikaci interních kalibračních tkání, a to i v případě kontrastních dat.


Tabulka 6-8: Parametry diskriminačního modelu obsahujícího pouze první dva příznaky s největší diskriminační silou pro tkáň zájmu na základě nativních dat.

Počet vstupních příznaků: 6			Počet zahrnutých příznaků: 2		
Intercept	RMSE	R-square	Adj R-sq	F	p-value
9,044	0,174	0,874	0,874	56186,20	0


Tabulka 6-9: Parametry výsledného diskriminačního modelu pro odlišení tkání zájmu na základě nativních dat.

Počet vstupních příznaků: 6			Počet zahrnutých příznaků: 5		
Intercept	RMSE	R-square	Adj R-sq	F	p-value
7,779	0,169	0,881	0,881	30084,20	0

Vysvětlení uvedených parametrů: Intercept – průsečík souřadnic, RMSE (z anglického „Root Mean Square Error“) – relativní střední kvadratická chyba, R-square – vysvětlená variance, Adj R-sq – přidaná vysvětlená variance, F – F-statistika, p-value – chyba I. řádu pro zvolenou hladinu významnosti.



Obrázek 6-13: Výstup shlukové analýzy algoritmem k-means (dělení do 5 shluků), kdy vstupem byly všechny příznaky zařazené do výsledného diskriminačního modelu pro odlišení tkání zájmu na základě nativních dat.



Obrázek 6-14: Výstup shlukové analýzy algoritmem k-means (dělení do 5 shluků), kdy vstupem byly pouze první dva příznaky s největší diskriminační silou pro tkáň zájmu na základě nativních dat.

6.3.2.3 Klasifikace vektoru texturních příznaků algoritmem k-means

Segmentace a následná klasifikace redukováného vektoru texturních příznaků byla provedena s využitím algoritmu k-means, jež náleží mezi metody shlukové analýzy. V rámci použití této metody bylo však nutné stanovit optimální počet shluků pro něž má probíhat vlastní dělení. To bylo realizováno na základě metody silhouette a subjektivního testování, kdy byly hodnoceny výstupy dělení do různého počtu shluků. Přičemž bylo zjištěno, že optimální počet shluků pro dělení algoritmem k-means v daném případě (pro kontrastní i nativní data) je 5.

Po provedené segmentaci vstupních obrazových dat na základě redukováného vektoru texturních příznaků s využitím algoritmu k-means bylo nutné identifikovat výsledné shluky jež náleží interním kalibračním tkání. To bylo realizováno metodou minimálních vzdáleností, a to konkrétně výpočtem Euklidovské vzdálenosti (definována vztahem: (6-2) [37]) ve vícerozměrném prostoru s využitím odvozených charakteristik tkání zájmu. Zmíněné charakteristiky byly určeny na základě databáze označených dat, a to pro kontrastní a nativní data zvlášť, přičemž určovanými parametry konkrétně byly: modus, medián, průměr a směrodatná odchylka (vyčíslené parametry viz. Tabulka 6-10). V rámci klasifikace byly tyto parametry počítány pro všechny výsledné shluky (v rámci vstupních obrazových dat) a jako shluk náležící dané tkáni zájmu byl zvolen ten shluk, jež dosahoval minimální hodnoty Euklidovské vzdálenosti mezi svými určenými charakteristikami a odvozenými charakteristikami dané tkáně zájmu.

$$D(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (6-2)$$

kde D je vypočtená Euklidovská vzdálenost, $\mathbf{x}$ a $\mathbf{y}$ jsou vstupní vektory (v našem případě vypočtené parametry daného shluku a odvozené charakteristiky dané tkáně zájmu), i je i -tý prvek daného vektoru a n je velikost daného vektoru (v našem případě 4).

Tabulka 6-10: Přehled stanovených charakteristik interních kalibračních tkání (modus, medián, průměr, směrodatná odchylka).


	Nativní data	Kontrastní data
Paraspinální sval	(31; 45; 48,34; 49,38)	(44; 58; 61,33; 51,26)
Podkožní tuková tkáň	(-95; -104; -106,79; 36,52)	(-90; -102; -105,90; 45,17)

6.3.3 Klasifikace algoritmem náhodného lesa

V rámci realizace klasifikace algoritmem náhodného lesa byly vytvořeny klasifikační modely pro kontrastní a nativní data zvlášť. V rámci učební fáze byla využita označená data z učební databáze patientských dat. Konkrétně byly v této fázi využívány intenzitní příznaky (na základě vstupních obrazových dat) z 3D okolí ohraničeného krychlí o hraně 5 voxelů (tvořící vektor intenzitních příznaků o velikosti 125), k nimž byla vždy přiřazena (na základě označených dat) klasifikační třída centrálního voxelu této oblasti. Takto byl vytvořen soubor vektorů intenzitních příznaků a k nim příslušných klasifikačních tříd přes celou učební databázi.

Bylo také nutné zvolit počet rozhodovacích stromů, jež bude v rámci učební fáze vytvářen. Tento parametr byl určen s ohledem na dosaženou úspěšnost klasifikace a také na časovou náročnost. Pro hodnocení úspěšnosti byla konkrétně počítána tzv. out-of-bag chyba (definována v teoretickém rozboru tohoto algoritmu), kdy bylo hodnoceno, od jakého počtu stromů nepřináší zapojení dalších stromů do rozhodovacího procesu relevantní změnu z hlediska snížení klasifikační chyby (viz. Obrázek 6-15). Na základě této analýzy byl konkrétně zvolen počet rozhodovacích stromů 100. Pro vlastní učební fázi daných stromů byla z celého souboru intenzitních vektorů pro každou klasifikační třídu (podkožní tuková tkáň, paraspinální sval a okolní tkáň) zvolena pouze část o definované velikosti (stejná pro všechny klasifikační třídy z důvodu rovnoměrného zastoupení v procesu učení daného modelu). Ta byla určena s ohledem na dosaženou úspěšnost výsledné klasifikace (hodnoceno opět na základě out-of-bag chyby modelu), ale také na časovou náročnost učení daného modelu a pak následného vybavování v procesu klasifikace. Konkrétně bylo zvoleno 80000 vektorů intenzitních příznaků pro danou klasifikační třídu, přičemž dané vektory byly z celého souboru vektorů voleny náhodně.

V rámci procesu vlastní klasifikace vstupních obrazových dat z testovací databáze byl vždy klasifikován vektor intenzitních příznaků z 3D okolí ohraničeného krychlí o hraně 5 voxelů. Přičemž výstupem vytvořeného náhodného lesa bylo zařazení centrálního voxelu této oblasti ke konkrétní klasifikační třídě na základě modu všech rozhodnutí vytvořeného souboru rozhodovacích stromů v daném náhodném lese obsažených.



Obrázek 6-15: Závislost out-of-bag chyby vytvořeného rozhodovacího modelu pro nativní data na počtu rozhodovacích stromů zapojených v klasifikačním procesu.

6.4 Testování možných modifikací

Na základě konzultací dosažených výsledků (popsány v následující sekci této práce) se spolupracujícím lékařem byly navrženy možné modifikace testovaných přístupů za účelem zlepšení klasifikační a segmentační účinnosti, ale také celkové funkčnosti těchto metod. Konkrétně byly navrženy tyto modifikace: redukce šumu ve vstupních obrazových datech, využití anatomické informace o lokalizaci interních kalibračních tkání a vyžití redukovaného vektoru texturních příznaků v rámci klasifikace algoritmem náhodného lesa. Popis jednotlivých modifikací je obsažen v následujících podsekcích, přičemž výsledky a celkové zhodnocení přínosu navrhaných modifikací budou popsány v následující kapitole této práce.

6.4.1 Redukce šumu

Pro redukci šumu obsaženého ve vstupních obrazových datech byl konkrétně použit modifikovaný algoritmus NLM (původní algoritmus popsán v teoretické části této práce), jenž byl publikován v rámci tohoto zdroje: [64]. Autoři této modifikované verze zavedli řadu vylepšení, a to hlavně za účelem snížení výpočetní a časové náročnosti původního algoritmu v rámci použití pro 3D obrazová data, ale také za účelem zlepšení celkové funkčnosti a využití tohoto algoritmu. Dle autorů tím bylo dosaženo plně automatické a optimalizované verze NLM filtru.

Konkrétně bylo autory odvozeno automatické nastavování stupně filtrace (parametru h), a to na základě hodnoty směrodatné odchylky šumu v daných obrazových datech. Další zavedenou modifikací byla preselekce nejvýznamnějších voxelů z hlediska podobnosti s analyzovanou oblastí, což je realizováno na základě podobnosti průměrů

oblastí o definované velikosti a na základě průměrné orientace gradientu daných oblastí. Tím jsou do následné filtrace zahrnuty pouze voxely, jež budou nabývat vysoké váhy (na základě podobnosti), a nepodobné voxely jsou ignorovány, čímž je dosaženo významného snížení výpočetního času. Poslední autory navržené modifikace souvisí majoritně se snížením časové náročnosti, přičemž byla konkrétně zavedena bloková implementace a paralelizace celkového výpočtu.

Pro vlastní praktickou realizaci bylo však nutné určit hodnotu směrodatné odchylky šumu v daných obrazových datech. Pro výpočet této hodnoty byla použita metoda odhadu šumu definována v rámci tohoto zdroje: [66]. Hodnota směrodatné odchylky šumu je získána na základě konvoluce vstupních 2D obrazových dat s dvojrozměrnou konvoluční maskou (odvozena na základě rozdílu dvou masek reprezentujících druhou derivaci na základě Laplaceanu daného obrazu viz. rovnice (6-4) [66]) a následného výpočtu s využitím autory odvozeného vzorce (viz. rovnice (6-3) [66]). Je patrné, že tato metoda je definována pouze pro dvojrozměrný prostor, a tudíž hodnota směrodatné odchylky šumu vstupních 3D dat byla určena jako průměr těchto hodnot určených z jednotlivých řezů.

$$\sigma_n = \sqrt{\frac{\pi}{2}} \frac{1}{6(W-2)(H-2)} \sum_I |I(x, y) * N|, \quad (6-3)$$

kde σ_n odpovídá směrodatné odchylce šumu daného obrazu I , jehož rozměry jsou W a H , a N je konvoluční maska definovaná rovnicí (6-4).

$$\begin{aligned} N = 2(L_2 - L_1) &= 2 \left(\frac{1}{2} \begin{bmatrix} 1 & 0 & 1 \\ 0 & -4 & 0 \\ 1 & 0 & 1 \end{bmatrix} - \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \right) \\ &= \begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix} \end{aligned} \quad (6-4)$$

Přičemž pro takto filtrovanou databázi patientských (srovnání původního nativního řezu a filtrovaného nativního řezu viz. Obrázek 6-16 a Obrázek 6-17) bylo nutné zopakovat všechny dílčí kroky související s testováním vybraných segmentačních a klasifikačních přístupů, jež byly popsány v předchozích částech této práce. V rámci globálního prahování bylo konkrétně nutné určit nové specifické intervaly CT hodnot interních kalibračních tkání (viz. Tabulka A-2). Pro postup s využitím texturní analýzy s klasifikací algoritmem k-means bylo určeno nové optimální nastavení pro výpočet matic současného výskytu a matic délky běhů (viz. Tabulka A-3, jediná změna oproti

nastavení pro původní data je, že u matic současného výskytu na základě nativních dat došlo ke zvolení jiného směru) a následně byla provedena redukce vektoru texturních příznaků (neredundantní 3D texturní příznaky jsou uvedeny v rámci tabulky (

Tabulka A-4)). Přičemž na základě provedené kanonické diskriminační analýzy bylo opět zjištěno, že pro vlastní diskriminaci mezi tkáněmi zájmu má majoritní význam příznak odpovídající lokálnímu průměru (pro kontrastní i nativní data). Pro následnou klasifikaci algoritmem k-mean byl optimální počet shluků stanoven jako 5 a byly vytvořeny nové charakteristiky tkání zájmů (uvedeny v tabulce: Tabulka A-5), přičemž celý klasifikační postup proběhl stejným způsobem jako u původních dat (viz. předchozí část této práce). V rámci klasifikace algoritmem náhodného lesa byly pouze naučeny nové modely pro takto filtrovaná kontrastní a nativní data.



Obrázek 6-16: Výřez z původních nativních vstupních dat (řez L2 obratlem daného pacienta).



Obrázek 6-17: Výřez z filtrovaných nativních dat (řez L2 obratlem daného pacienta).

6.4.2 Využití anatomické informace o lokalizaci interních kalibračních tkání

Další navrženou modifikací bylo využití anatomické informace o lokalizaci interních kalibračních tkání. K tomu byla využita informace o lokalizaci polohy centroidu daného obratle v rámci vstupních dat (výstup dalšího souběžně probíhajícího projektu v rámci spolupráce s firmou Philips), kolem něhož byla následně vymezena nová oblast pro vlastní segmentaci a klasifikaci interních kalibračních tkání. Tím došlo ke zmenšení analyzované oblasti a výrazné eliminaci výskytu okolních měkkých tkání (viz. Obrázek 6-18 a Obrázek 6-19).



Obrázek 6-18: Původní výřez z nativních vstupních dat (řez L2 obratlem daného pacienta).



Obrázek 6-19: Výřez z nativních vstupních dat s využitím anatomické informace o lokalizaci interních kalibračních tkání (řez L2 obratlem daného pacienta).

6.4.3 Využití redukovaného vektoru texturních příznaků pro klasifikaci algoritmem náhodného lesa

Dále bylo testován přínos zahrnutí vektoru neredundantních 3D texturních příznaků v rámci klasifikace algoritmem náhodného lesa. Tato modifikace byla uvažována pouze pro původní nefiltrovaná vstupní dat. Jelikož, jak bylo popsáno v teoretické části zabývající se tímto algoritmem, v rámci procesu vytváření vlastních rozhodovacích stromů jsou vstupní atributy voleny náhodně ze vstupního vektoru příznaků, tudíž zařazení neredundantních texturních příznaků na základě filtrovaných dat (2 příznaky pro kontrastní data a 3 příznaky pro nativní data) by bylo málo pravděpodobné. Uvažováno bylo i zahrnutí celého vektoru 3D texturních příznaků (198 příznaků pro voxel), to však bylo s ohledem na časovou a výpočetní náročnost zavrženo. Pro realizaci uvažované modifikace bylo nutné zmiňovaný vektor neredundantních příznaků vypočítat pro celou učební databázi patientských dat. Vypočtené neredundantní 3D texturní příznaky byly následně využity v rámci učební fáze. Ta proběhla obdobným způsobem, jež byl popsán v sekci zabývající praktickou realizací klasifikace algoritmem náhodného lesa. Přičemž počet vytvářených stromů a počet použitých příznakových vektorů v rámci učební fáze zůstal stejný jako v případě nefiltrovaných dat. Jedinou změnou byla velikost vstupních příznakových vektorů. Ty nyní obsahovaly intenzitní informaci z 3D oblasti vymezenou krychlí o hraně 5 voxelů (125 příznaků) a také neredundantní texturní příznaky vypočtené z této oblasti (viz. Tabulka 6-7). Takto vytvářené příznakové vektory byly využity i v rámci procesu vlastní klasifikace obrazových dat z testovací databáze.

6.5 Hodnocení dosažených výsledků

Úspěšnost klasifikace jednotlivých testovaných přístupů a přínos navržených modifikací byly vyhodnocovány voxelově, a to na základě překryvů automaticky označených dat (jednotlivými metodami) s manuálně označenými daty (považovanými jako zlatý standard). Přičemž toto hodnocení bylo provedeno na testovací databázi patientských dat, a to pro kontrastní a nativní data zvlášť. Na základě určených překryvů byly následně vypočteny hodnoty tří zvolených parametrů. Těmi konkrétně byly: senzitivita (definována vztahem (6-5) [68]), Sørensen–Dice koeficient (definován vztahem (6-6) [37]) a celková úspěšnost (definována vztahem (6-7)). Přičemž konkrétní dosažené výsledky jsou uvedeny a diskutovány v následující kapitole této práce.

$$\text{Senzitivita} = \frac{TP}{TP+FN}, \quad (6-5)$$

$$DSC = \frac{2TP}{2TP+FP+FN}, \quad (6-6)$$

$$\text{Celková úspěšnost} = \frac{\text{počet voxelů správně}}{\text{počet voxelů celkově}} \cdot 100\% \quad [\%], \quad (6-7)$$

kde TP v našem případě označuje správně klasifikované voxely pro danou tkáň, FN voxely jež měly být označeny jako daná tkáň, ale nebyly, TN voxely jež správně nebyly označeny jako daná tkáň, *počet voxelů správně* je dán jako suma hodnot TP pro všechny klasifikační třídy (paraspinální sval, podkožní tuková tkáň a ostatní tkáně).

Testované přístupy byly však také hodnoceny z hlediska jejich funkčnosti pro následný výpočet hodnoty minerální denzity obratlů. Přičemž byla konkrétně hodnocena odchylka od hodnoty BMD stanovené na základě zlatého standardu (manuálně označených dat) a hodnoty BMD stanovené na základě výstupů jednotlivých testovaných metod. Pro výpočet minerální denzity byla zvolena metoda, jež byla popsána v sekci této práce zabývající se publikovanými postupy výpočet BMD na základě CT dat (konkrétně vůbec první publikovaná metoda: [4]). Prakticky byla stanovována hodnota minerální denzity daného obratle ve zvoleném řezu, přičemž pro vlastní výpočet bylo ještě nutné vymezit oblast trabekulární kosti daného obratle, což bylo realizováno manuálně.

7. Implementace metodologického řešení

Pro realizaci navrženého metodologického řešení byla vytvořena a použita řada funkcí a skriptů pro jednotlivé testované přístupy, jež byly implementovány v programovacím prostředí Matlab®, a to ve verzích 2014a a 2015a, a jejichž popis je předmětem této kapitoly. Přičemž převážná část testování proběhla na výpočetním serveru s parametry: procesor Intel® Xeon® 2.53 GHz (počet procesorů 2), RAM 192 GB a 64 bitovým systémem. Pouze malá část testování, převážně související se statistickým vyhodnocováním, byla realizována na notebooku s těmito parametry: procesor Intel® Core™ i5-3210M 2.50 GHz, RAM 4,00 GB a 64 bitovým operačním systémem. Zmíněný server byl majoritně využívám z důvodu výpočetní ale také paměťové náročnosti celého procesu testování.

7.1 Globální prahování

Pro testování této metody byla vytvořena funkce `thresholding.m`, jež je definována předpisem (7-1). Je patrné, že tato funkce má tři vstupy a jeden výstup, které jsou popsány níže. V rámci těla této funkce proběhne vlastní prahování, kdy na základě vstupů: `vstup2` a `vstup3` jsou voleny specifické intervaly intenzitních hodnot (Tabulka 6-1 a Tabulka A-2) pro interní kalibrační tkáň. Přičemž vstupním voxelům náležícím podkožní tukové tkáni je na výstupu přiřazena hodnota 2, paraspinálnímu svalu hodnota 1 a voxelům náležícím okolním tkáním hodnota 0.

$$[\text{vystup}] = \text{thresholding}(\text{vstup1}, \text{vstup2}, \text{vstup3}) \quad (7-1)$$

1. `vstup1` – vstupní analyzovaná 3D obrazová data (3D matice).
2. `vstup2` – logická informace, zda se jedná o filtrovaná (1) anebo nefiltrovaná (0) data.
3. `vstup3` – logická informace, zda se jedná o kontrastní (1) anebo nativní (0) data.
4. `vystup` – výstupní prahovaná data (3D matice), kdy podkožní tukové tkáni je přiřazena hodnota 2, paraspinálnímu svalu hodnota 1 a ostatním tkáním hodnota 0.

7.2 Texturní analýza s klasifikací texturních příznaků algoritmem k-means

Na základě provedené analýzy texturních příznaků a hledání optimálního nastavení pro tento testovaný přístup (popsáno v předchozí kapitole) byla vytvořena funkce `Texture_classification.m` (definována předpisem (7-2)) realizující výpočet relevantních texturních příznaků a jejich následnou klasifikaci. Výstup této funkce a její vstupy jsou popsány níže. V rámci vlastního těla funkce dojde k výpočtu vektoru relevantních 3D texturních příznaků s využitím vytvořené funkce `Texture_analysis.m` (definována předpisem (7-3)), pro výpočet použity matlabovské funkce `mean` a `std`. Dále proběhne shluková analýza algoritmem k-means (funkce `kmeans`: maximální počet iterací zvolen 500, počet replikací celého procesu 10 a byla využita možnost paralelizace), přičemž dělení proběhne do odvozeného optimálního počtu shluků (5), kdy v testovací fázi byla pro realizaci metody silhouette využita matlabovská funkce `evalclusters`. Výsledné shluky jsou následně klasifikovány. K tomu jsou využity ve funkci uložené charakteristiky tkání zájmů (Tabulka 6-10 a Tabulka A-5), jež jsou voleny na základě vstupních parametrů, a výpočet Euklidovské vzdálenosti ve vícerozměrném prostoru (funkce `pdist2`). Sledované charakteristiky (modus – `mode`, medián – `median`, průměr – `mean` a směrodatná odchylka – `std`) jsou vypočteny pro jednotlivé shluky a k dané tkáni zájmu je přiřazen shluk s vůči ní nejnížší vypočtenou Euklidovskou vzdáleností.

```
[data_class] = Texture_classification(data,          (7-2)  
hrana, filtrace, kontrast)
```

1. `data` – vstupní analyzovaná 3D obrazová data (3D matice).
2. `hrana` – velikost hrany krychle vymezující 3D oblast pro výpočet příznaků.
3. `filtrace` – logická informace, zda se jedná o filtrovaná (1) anebo nefiltrovaná (0) data.
4. `kontrast` – logická informace, zda se jedná o kontrastní (1) anebo nativní (0) data.
5. `Data_class` – klasifikovaná vstupní data (3D matice), kdy podkožní tukové tkáni je přiřazena hodnota 2, paraspinálnímu svalu hodnota 1 a ostatním tkáním hodnota 0.

```
[priznaky] = Texture_analysis(data, hrana,          (7-3)  
filtrace)
```

1. `data` – vstupní analyzovaná 3D obrazová data (3D matice).

2. *hrana* – velikost hrany krychle vymezující 3D oblast pro výpočet příznaků.
3. *filtrace* – logická informace, zda se jedná o filtrovaná (1) anebo nefiltrovaná (0) data.
4. *priznaky* – vektor vypočtených relevantních 3D texturních příznaků.

7.2.1 Dílčí použité funkce

7.2.1.1 Výpočet kompletního vektoru texturních příznaků

Pro výpočet kompletního vektoru 3D texturních příznaků byla použita vytvořená funkce `Texture_features.m` (definovaná vztahem (7-4)), v rámci níž je celkově počítáno 198 příznaků pro voxel (seznam příznaků uveden v: Tabulka A-1). Výpočet texturních příznaků na základě statistických metod prvního řádu je realizován s využitím funkcí dostupných ve statistickém toolboxu (lokální průměr – `mean`, lokální směrodatná odchylka – `std`, lokální průměrná absolutní odchylka – `mad`, lokální rozptyl – `var`, lokální špičatost – `kurtosis`, lokální šikmost – `skewness` a lokální entropie – `entropy`).

V rámci výpočtu texturních příznaků na základě statistických metod druhého řádu je pro vytváření matic současného výskytu použita volně dostupná funkce `cooc3d.m` (vstup: 3D oblast ze vstupních dat ohraničená krychlí o hraně 5 voxelů, parametr vzdálenosti, počet počítaných příznaků a parametr udávající směr; výstup: texturní příznaky a vlastní matice současného výskytu) [69] a pro vytváření matic délky běhů je využita vytvořená funkce `grayrlmatrix_3D.m` (vstup: 3D oblast ze vstupních dat ohraničená krychlí o hraně 5 voxelů, počet kvantovacích hladin a parametr udávající směr; výstup: matice délky běhů). Ta je založena na volně dostupné funkci `grayrlmatrix.m` [70], ale byla rozšířena tak, aby umožňovala výpočet dané matice i ve 3D. Vstupní hodnoty parametrů vzdálenosti a směrů jsou voleny na základě odvozeného optimálního nastavení pro tyto matice (Tabulka 6-5 a Tabulka A-3). Parametr udávající počet kvantovacích hladin nutný pro výpočet matic délky běhů je určován lokálně, a to na základě analýzy vytvářeného histogramu (hledán počet intenzit s nenulovou četností). Přičemž pro následný výpočet texturních příznaků na základě těchto matic jsou opět využity volně dostupné funkce, pro matice současného výskytu: `GLCM_Features4.m` [71] (16 texturních příznaků definovaných v rámci tohoto zdroje: [30]) a pro matice délky běhů: `grayrlprops.m` [72] (11 příznaků definovaných v rámci tohoto zdroje: [31]), kdy vstupem je v obou případech daná matice.

Pro výpočet texturních příznaků na základě lokální spektrální analýzy je pro výpočet spektrální koeficientů ze vstupní 3D oblasti (ohraničená krychlí o hraně 9 voxelů) využita

funkce `fftn` umožňující výpočet rychlé diskrétní n -dimenzionální Fourierovy transformace. Použitá funkce umožňuje výpočet spektra o definované velikosti, kdy konkrétně byly zvoleny rozměry $21 \times 21 \times 21$, přičemž toto rozšíření výsledného spektra je realizováno prokládáním nulami. Následně jsou počítány příznaky odpovídající parametrickému výkonu a relativnímu parametrickému výkonu, a to vždy pro jednotlivá frekvenční pásma vymezená vytvořenými binárními maskami. V rámci mikrotextrní analýzy byla pro konvoluci vstupních obrazových dat s Lawsovými maskami využita funkce `convn` umožňující n -dimenzionální konvoluci.

```
[priznaky] = Texture_analysis(data, hrana1,          (7-4)
hrana2, kontrast, filtrace)
```

1. `data` – vstupní analyzovaná 3D obrazová data (3D matice).
2. `hrana1` – velikost hrany krychle vymežující 3D oblast pro výpočet příznaků na základě statistických metod prvního a druhého řádu.
3. `hrana2` – velikost hrany krychle vymežující 3D oblast pro výpočet příznaků na základě spektrální analýzy.
4. `kontrast` – logická informace, zda se jedná o kontrastní (1) anebo nativní (0) data.
5. `filtrace` – logická informace, zda se jedná o filtrovaná (1) anebo nefiltrovaná (0) data.
6. `priznaky` – vypočtený vektor 3D texturních příznaků.

7.2.1.2 *Redukce redundantních příznaků*

Pro redukci vektoru 3D texturních příznaků o redundantní příznaky, na základě korelační analýzy a analýzy hlavních komponent, byl vytvořen skript `Redukce_redundantnich_priznaku.m`. V rámci něhož dojde po načtení vektoru texturních příznaků (sloupce odpovídají jednotlivým příznakům) k ošetření výskytu komplexních hodnot (funkce `real`) a také výskytu hodnot $\pm \infty$ (odstranění pozic jejich výskytu v rámci všech příznaků). Následně dojde k normalizaci (min-max normalizace) jednotlivých příznaků (sloupce vstupního vektoru) a ošetření výskytu NaN hodnot (odstranění pozic jejich výskytu v rámci všech příznaků). V další fázi dojde k výpočtu matice obsahující Pearsonovy korelační koeficienty mezi jednotlivými příznaky (funkce `corr`). Prahováním je na základě této matice vytvořena pomocná matice obsahující hodnoty 1, tam kde Pearsonův korelační koeficient měl v absolutní hodnotě hodnotu vyšší než 0,85 (příznaky spolu silně korelovaly), a hodnoty 0 na ostatních pozicích. Následně probíhá `while` cyklus, kde je počítán sloupcový sumační vektor pomocné matice a v něm je detekována pozice maxima (příznak jež koreluje s nejvíce příznaky), následně je určeno, s kterými příznaky tento nejvíce korelovaný příznak konkrétně koreluje, a

pozice odpovídající těmto příznakům jsou v pomocné matici nulovány. Tento cyklus probíhá až do doby, dokud nejsou odhaleny všechny korelované příznaky, přičemž vstupní vektor je poté o tyto příznaky redukován.

Takto redukováný vektor je následně podroben analýze hlavních komponent, kdy je využita funkce `pca`, přičemž na základě ní vypočítané parametry jsou poté analyzovány. Vhodný počet faktorových os je odhadován na základě implementovaného Kaiser-Gutmanova kritéria, kdy je na základě sumy hodnot eigenvalues automaticky určeno, zda výpočet faktorových os byl založen na kovarianční matici (v tom případě hledány faktorové osy s eigenvalue vyšším jak jejich průměrná hodnota) nebo korelační matici (v tom případě hledány faktorové osy s eigenvalue vyšším jak 1). Dále je také využito Scree-plotu (grafické hledání maximálního zlomu ve vztahu mezi počtem os a vyčerpanou variabilitou), kdy hledaný maximální zlom je detekován s využitím určení maximální hodnoty druhé derivace (použita funkce `diff`) daného vektoru eigenvalues. Finální volba je však na uživateli. Po zvolení vhodného počtu faktorových os je vykreslen biplot korelací těchto os, na jehož základě lze zvolit neredundantní příznaky, jež nejvíce korelují s danými osami (vyčerpávají největší podíl z vyčerpané variability). Přičemž tato volba je opět na zvážení uživatele.

7.3 Klasifikace algoritmem náhodného lesa

Pro realizaci této testované metody byl vytvořen skript `Random_forest_classification.m`, v němž probíhají tři dílčí na sebe navazující fáze. Nejprve je procházena učební databáze, kdy je tvořena matice obsahující učební vektory příznaků (intenzitní informace z 3D oblasti vstupních dat ohraničené krychlí o zvolené velikosti hrany) a také je vytvářen vektor obsahující klasifikační třídy centrálních voxelů jednotlivých vektorů příznaků. To je realizováno načítáním obrazových dat jednotlivých obrátek a k nim příslušných označených dat, kdy učební vektory jsou vytvářeny pouze kolem řezů, jež byly označeny. V další fázi je z takto vytvořené matice učebních příznaků s využitím vektoru příslušných klasifikačních odezev náhodně zvolena pouze jeho část o definované velikosti, přičemž v této nové učební matici je každá klasifikační třída rovnoměrně zastoupena (popsáno v předchozí kapitole). Následuje učení vlastního náhodného lesa, k čemuž je využita funkce `TreeBagger`, kdy vstupem je zvolený počet stromů (volba popsána v předchozí kapitole), matice učebních příznakových vektorů, vektor odpovídajících klasifikačních tříd a je zvolena úloha daného lesa (v našem případě klasifikace). Poslední fází je klasifikace dat z testovací databáze, kdy je tato databáze procházena a jsou načítána obrazová data jednotlivých obrátek. Z těchto dat je vždy vytvořena matice obsahující

vektory příznaků, jež jsou následně klasifikovány vytvořeným náhodným lesem za využití funkce `predict`. Tím je získán vektor klasifikačních tříd odpovídajících vstupním příznakovým vektorům, jež je následně přeskládán do odpovídajících obrazových rozměrů (funkce `reshape`).

7.4 Filtrace šumu algoritmem NLM

Filtrace šumu zvoleným modifikovaným algoritmem NLM (popsán v předchozí kapitole a definován v rámci tohoto zdroje: [64]) byla realizována vytvořenou funkcí `NLM_noise_reduction.m` (definována předpisem: (7-5)), kdy pro vlastní filtraci byla využita implementovaná funkce `MBONLM3D` od autorů vlastní modifikace. Ta byla realizována na platformě C++ a byla volně ke stažení (v rámci tohoto zdroje: [73]) i ve verzi určené pro Matlab®. Pro vlastní redukci šumu jsou použity autory odvozené optimální parametry ($w = 3$ (tj. poloměr prohledávané 3D oblasti) a $f = 1$ (tj. poloměr 3D oblasti pro výpočet podobností)), hodnota směrodatné odchylky šumu a je zvolena filtrace Gaussovského šumu. Pro výpočet směrodatné odchylky šumu byla vytvořena funkce `NoiseEstimation.m` (definována předpisem: (7-6)), v rámci níž byla implementována v předchozí kapitole popsána metoda odhadu šumu a následného výpočtu směrodatné odchylky tohoto šumu (definována v rámci tohoto zdroje: [66]). Tato metoda je definována pouze pro dvojrozměrná data, a tudíž je prováděn výpočet pro všechny řezy vstupních dat, a výsledná hodnota směrodatné odchylky šumu je získána jako průměr těchto hodnot z jednotlivých řezů.

`[data_filt] = NLM_noise_reduction(data)` (7-5)

1. `data` – vstupní 3D obrazová data (3D matice).
2. `Data_filt` – filtrovaná vstupní 3D obrazová data.

`[Sigma] = NoiseEstimation(Img)` (7-6)

1. `Img` – vstupní 2D obraz.
2. `Sigma` – vypočtená hodnota směrodatné odchylky šumu.

7.5 Hodnocení úspěšnosti

Pro hodnocení testovaných přístupů z hlediska klasifikační úspěšnosti byl vytvořen skript `hodnoceni_uspesnosti.m`. V rámci něhož je procházena testovací databáze a jsou vždy načítány výstupy jedné z testovaných metod pro daný obratel a také

odpovídající manuálně označená data. Pro načtený obratel vždy proběhne určení parametrů nutných pro následný výpočet hodnocených veličin (Senzitivita, Sørensen–Dice koeficient a celková úspěšnost – definovány v předchozí kapitole). Pro určení těchto parametrů (TP, FP, FN) byla vytvořena funkce `uspesnost.m` (definována předpisem: (7-7)), přičemž tyto parametry jsou počítány pro každou klasifikační třídu zvlášť. Parametry odpovídající všem klasifikačním třídám u daného obratle jsou ukládány a výpočet hodnocených veličin je realizován až pro celou databázi (pro kontrastní a nativní data zvlášť).

$$[TP, FP, FN, TN] = \text{uspesnost}(\text{data_class}, \text{zlaty_standard}, \text{label}) \quad (7-7)$$

1. `data_class` – klasifikovaná data.
2. `zlaty_standard` – manuálně označená data.
3. `label` – hodnocená klasifikační třída.
4. TP – počet správně klasifikovaných voxelů jako daný label.
5. FP – počet voxelů špatně označených jako daný label.
6. FN – počet neoznačených voxelů daného labelu.
7. TN – počet správně neoznačených voxelů jako daný label.

Pro druhou fázi hodnocení, tj. z hlediska funkčnosti testovaných metod pro následný výpočet minerální denzity obratlů, byla Bc. Oldřichem Kodymem (autor souběžně vytvářené diplomové práce zabývající se výpočtem hodnoty BMD obratlů na základě CT dat) vytvořena funkce `getbmd.m` (definována předpisem: (7-8)) v rámci níž byla implementována zvolená metoda stanovování hodnoty BMD (první publikovaná metoda [4]). S využitím této funkce byla stanovována hodnota minerální denzity [mg/cm^3] daného obratle ve zvoleném řezu. Přičemž vstupy této funkce jsou vektory intenzitních hodnot odpovídajících interním kalibračním tkáním (získány na základě výstupů testovaných metod a zlatého standardu) a vektor intenzitních hodnot odpovídající trabekulární kosti daného obratle (manuálně určován). Vstupní vektory jsou v rámci této funkce proloženy normálním rozložením a jsou detekována maxima těchto proložení. Tyto hodnoty jsou následně využity pro vlastní výpočet kostní minerální denzity, jež je realizován na základě lineární regrese. Přičemž jsou počítány hodnoty BMD s využitím označených dat jednotlivými metodami a jsou hodnoceny odchylky těchto hodnot od referenční hodnoty (tj. hodnota BMD určená s využitím manuálně označených dat).

$$\text{BMD} = \text{getbmd}(\text{data_bone}, \text{data_fat}, \text{data_muscle}) \quad (7-8)$$

1. `data_bone` – vektor intenzitních hodnot zdravé trabekulární kosti.


2. `data_fat` – vektor intenzitních hodnot podkožní tukové tkáně.
3. `Data_muscle` – vektor intenzitních hodnot paraspinálního svalu.
4. `BMD` – hodnota vypočtené minerální denzity.

7.6 Finální implementační řešení

Na základě vyhodnocení celkových výsledků byla pro úlohu segmentace a klasifikace interních kalibračních tkání vytvořena funkce `internal_phantoms_classification.m` (definována předpisem: (7-9)). V rámci níž je využita anatomická informace o lokalizaci daných tkání, kdy je proveden ořez vstupních dat na základě polohy centroidu daného obrátle. Následně dojde k filtraci vstupních dat s využitím funkce `NLM_noise_reduction.m` (popsána dříve). Pro vlastní klasifikaci je využit algoritmus náhodného lesa, kdy podle typu dat, z hlediska aplikace kontrastní látky, dojde k načtení odpovídajícího modelu. Ořezaná a filtrovaná vstupní data jsou následně převedena na příznakové vektory a daným modelem klasifikována. Blokové schéma dané funkce je uvedeno v rámci obrázku: Obrázek 7-1.

`data_class = uspesnost(data, centroid, kontrast)` (7-9)


1. `data` – vstupní 3D obrazová data.
2. `centroid` – poloha středu daného obrátle vůči osám x a y .
3. `kontrast` – logická informace, zda se jedná o kontrastní (1) anebo nativní (0) data.
6. `data_class` – klasifikovaná vstupní data (3D matice), kdy podkožní tukové tkáni je přiřazena hodnota 2, paraspinálnímu svalu hodnota 1 a ostatním tkáním hodnota 0.



Obrázek 7-1: Blokové schéma finální funkce. Vstupy (a), probíhající činnosti (b) a výstup (c).

8. Diskuze dosažených výsledků

Na základě obrazových výstupů testovaných metod (Obrázek 8-1) je patrné, že v žádném z případů nedošlo k naprosto přesné klasifikaci a segmentaci interních kalibračních tkání. Je zřejmé, že žádné z metod se nepodařilo od sebe odlišit podkožní tukovou tkáň a útrobní tukovou tkáň, přičemž v rámci klasifikace paraspinálního svalu, docházelo k označování okolních měkkých tkání jako daného svalstva. To v obou případech souvisí s překrývajícími se intervaly CT hodnot daných tkání a podobností z hlediska texturní informace. V případě globálního prahování (Obrázek 8-1 b)) a texturní analýzy s klasifikací texturních příznaků algoritmem k-means (Obrázek 8-1 c)) nedošlo ani k úspěšnému odlišení tkání zájmu od trabekulární kosti daného obratle. U posledně jmenovaného přístupu také docházelo k označování kortikální části daného obratle jako paraspinálního svalu, majoritně v oblasti jeho příčných výběžků. To souvisí s nízkou prostorovou klasifikační přesností daného přístupu, kdy tato oblast dosahuje nízké tloušťky, jež je evidentně pod rozlišovací schopností dané metody.



Obrázek 8-1: Výsledky testovaných metod pro zvolený řez (nativní L2 obratel):
a) Manuálně označená data (zlatý standard); b) Globální prahování; c) Texturní analýza + algoritmus k-means; d) Náhodný les. **Legenda:** šedá barva – paraspinální sval, bílá barva – podkožní tuk.

Předchozí subjektivní hodnocení je v korelaci se statickými výsledky pro jednotlivé přístupy, jejichž výstupy byly hodnoceny vůči manuálně označené databázi, a to pro nativní data (viz. Tabulka 8-1) a kontrastní data zvlášť (viz. Tabulka A-6). Je zřejmé, že klasifikace na základě texturní analýzy s klasifikací texturních příznaků algoritmem k-means dosáhla vysokých (v případě nativních dat vůbec nejvyšších) hodnot senzitivity pro obě tkáně zájmu, ale nejhorší celkové úspěšnosti. Oproti tomu nejvyšší celkové úspěšnosti dosáhl klasifikační algoritmus náhodného lesa, což bylo zřejmé i z jeho obrazových výstupů (Obrázek 8-1 d)). Nízké hodnoty Sørensen–Dice koeficientu pro paraspinální sval u všech testovaných přístupů souvisí se špatnou klasifikací okolních měkkých tkání jako daného svalu, kdy nejvíce tato situace zřejmě nastává v rámci klasifikace s využitím globálního prahování. Na základě hodnot tohoto koeficientu pro podkožní tuk lze také usuzovat, že u globálního prahování a texturní analýzy dochází také k významnému falešně pozitivnímu označování z hlediska této tkáně. Je patrné, že u algoritmu náhodného lesa k takto falešně pozitivnímu označování pro obě tkáně zájmu dochází v nejmenší míře (oproti ostatním testovaným přístupům), což celkově svědčí o nejlepší funkčnosti tohoto přístupu pro danou úlohu.

Tabulka 8-1: Výsledky testovaných přístupů na testovací databázi nativních dat.

	Globální prahování	Texturní analýza + k-means	Náhodný les
Senzitivita sval	0,82	0,87	0,78
Senzitivita tuk	0,76	0,99	0,84
DSC sval	0,31	0,34	0,40
DSC tuk	0,36	0,38	0,63
Celková úspěšnost [%]	41,66	36,65	68,77

V rámci testování navržených modifikací realizace dané úlohy, jež byly dříve popsány, bylo zjištěno, že nejvyšší přínos, z hlediska funkčnosti testovaných přístupů, má kombinace využití anatomické informace o lokalizaci interních kalibračních tkání a redukce šumu ve vstupních datech. Konkrétně bylo ve všech případech na databázi nativních dat dosaženo zlepšení z hlediska celkové úspěšnosti o více než 10 % (viz. Tabulka 8-2), čímž bylo u algoritmu náhodného lesa dosaženo celkové úspěšnosti skoro

80 % (viz. Tabulka 8-3). V rámci databáze kontrastních dat nebylo dosaženo tak výrazného zlepšení u všech testovaných přístupů (viz. Tabulka A-16). V případě klasifikačního náhodného lesa bylo dosaženo zlepšení pouze o 2,39 %, ale celková úspěšnost daného přístupu tím dosáhla hodnoty 78 % (Tabulka A-15). Největší význam, z hlediska zlepšení funkčnosti, měly provedené modifikace v rámci globálního prahování, což svědčí o významném negativním vlivu šumu pro klasifikaci tímto přístupem. Pouze v případě texturní analýzy měla provedená redukce šumu negativní vliv, a to pro oba typy dat (viz. Tabulka A-8 a Tabulka A-10). To může souviset s obecně negativním vlivem redukce šumu na výslednou ostrost daných obrazových dat (k čemuž by však u zvoleného typu filtrace mělo docházet v minimální míře) a také s potlačením šumové texturní informace. Přínos využití anatomické informace (viz. Tabulka A-12 a Tabulka A-14), realizované ořezáním vstupních dat kolem polohy centroidu daného obrátle, souvisí s výraznou eliminací výskytu okolních měkkých tkání, čímž bylo dosaženo snížení počtu falešně pozitivních klasifikací, majoritně z hlediska paraspinálního svalu. V rámci testování využití vektoru neredundantních 3D texturních příznaků pro klasifikaci algoritmem náhodného lesa bylo zjištěno, že tato modifikace nepřináší výrazné změny (viz. Tabulka A-17 a Tabulka A-18) a navíc není, jak bylo již dříve popsáno, vhodná pro filtrovaná data.

Tabulka 8-2: Přínos využití anatomické informace o lokalizaci interních kalibračních v kombinaci s redukcí šumu ve vstupních datech pro výsledky testovaných přístupů na databázi nativních dat.

	Globální prahování	Texturní analýza + k-means	Náhodný les
Senzitivita sval	-0,01	0,00	0,08
Senzitivita tuk	-0,06	-0,01	0,06
DSC sval	0,25	0,18	0,28
DSC tuk	0,19	0,17	0,23
Celková úspěšnost [%]	17,01	10,49	10,48


Tabulka 8-3: Výsledky testovaných přístupů s využitím anatomické informace o lokalizaci interních kalibračních tkání v kombinaci s redukcí šumu na databázi nativních dat.

	Globální prahování	Texturní analýza + k-means	Náhodný les
Senzitivita sval	0,81	0,87	0,86
Senzitivita tuk	0,70	0,98	0,90
DSC sval	0,56	0,52	0,68
DSC tuk	0,55	0,55	0,86
Celková úspěšnost [%]	58,67	47,14	79,25

Pro výstupy testovaných přístupů bylo také vyžádáno lékařské zhodnocení. Spolupracující lékař byl konkrétně zapojen do slepé studie, v rámci níž hodnotil obrazové výstupy jednotlivých přístupů bez znalosti původu těchto výstupů. Nezávisle na statistických výsledcích došlo k potvrzení nejlepší funkčnosti algoritmu náhodného lesa pro klasifikaci interních kalibračních tkání. Nejhorších výsledků dle daného lékaře dosáhla texturní analýza s klasifikací texturních příznaků algoritmem k-means, a to z důvodu nízké prostorové klasifikační schopnosti a vysokého počtu falešně pozitivních označení. To bylo problémem i u globálního prahování, jež však již dosahovalo lepší prostorové klasifikační schopnosti. Lékař hodnotil také navržené modifikace celého postupu, přičemž došlo opět k potvrzení statistického vyhodnocení, kdy jako modifikace s nejvyšším přínosem byla zvolena kombinace ořezání a filtrace vstupních dat.

V rámci vyhodnocování výstupů testovaných přístupů byla také hodnocena jejich funkčnost pro následný výpočet minerální denzity obratlů. Konkrétně byly testovány výstupy získané s využitím kombinace filtrace vstupních dat a využití anatomické informace (případ, kde všechny přístupy dosáhly jejich nejvyšší úspěšnosti). Na základě dosažených výsledků je patrné, že celkově nejmenší odchylky vůči referenční hodnotě (stanovené na základě manuálně označených dat) ve zvolených 10 řezech lumbálními obratli nativního pacienta, na nichž proběhlo dané testování, dosáhl algoritmus náhodného lesa (viz. Obrázek 8-2). Tento algoritmus konkrétně dosáhl průměrné odchylky 5,46 mg/cm³. Nejvyšší průměrné odchylky dosáhlo globální prahování, a to 29,46 mg/cm³. Je patrné, že u těchto dvou intenzitních přístupů docházelo

k nadhodnocování z hlediska referenční hodnoty BMD. Oproti tomu v případě texturní analýzy docházelo spíše k podhodnocování, kdy tento přístup dosáhl konkrétně průměrné odchylky $-13,95 \text{ mg/cm}^3$.



Obrázek 8-2: Grafické znázornění odchylek stanovených hodnot BMD, pro dané řezy těly nativních obratlů, s využitím klasifikačních výstupů jednotlivých testovaných metod vůči referenčním hodnotám stanovených s využitím databáze manuálně označených dat.

Závěr

V této práci je řešena úloha automatické klasifikace a segmentace interních kalibračních tkání za účelem jejich následného využití pro výpočet minerální denzity obratlů. Pro vlastní řešení byly testovány tři zvolené přístupy, a to globální prahování, texturní analýza s klasifikací texturních příznaků algoritmem k-means a klasifikace algoritmem náhodného lesa. Pro zlepšení celkové funkčnosti testovaných přístupů byly na základě konzultací se spolupracujícím lékařem navrženy modifikace, jež byly následně testovány.

V rámci teoretické části této práce je nejprve popsána problematika stanovování minerální kostní denzity obecně a specificky pak stavování této hodnoty pro těla obratlů na základě běžných CT s využitím interních kalibračních tkání. Dále rešerše obsahuje popis segmentačních a klasifikačních metod, přehled publikací zabývajících se segmentací a klasifikací daných tkání zájmu a popis využitých statistických metod a zvoleného algoritmu pro redukci šumu. V dalších částech práce je popsáno vlastní navržené metodologické a následně implementační řešení dané úlohy. Konkrétně jsou popsány jednotlivé dílčí kroky spojené s realizací testovaných přístupů a jejich následná implementace v programovacím prostředí Matlab®. V poslední části jsou diskutovány dosažené výsledky testovaných přístupů, jež byly statisticky hodnoceny na základě překryvů s vytvořenou databází manuálně označených dat, kdy konkrétně byla počítána senzitivita, Sørensen–Dice koeficient a celková úspěšnost. Vyžádáno bylo také lékařské zhodnocení dosažených obrazových výstupů a byla také testována celková funkčnost daných přístupů pro následný výpočet hodnoty BMD obratlů.

Nejlepší celkové úspěšnosti dosáhl klasifikační algoritmus náhodného lesa, a to pro nativní i kontrastní data. Naopak nejhorších výsledků dosáhla texturní analýza s klasifikací texturních příznaků algoritmem k-means, kdy lepších výsledků dosáhlo i globální prahování, jež je z hlediska principu méně sofistikovanou metodou. To svědčí o celkově nízkém významu texturní informace pro danou úlohu, což souvisí s významnou podobností tkání vyskytující se v daných obrazových datech právě z hlediska texturních vlastností. Oproti tomu bylo zjištěno, že celkově nejvyšší segmentační a klasifikační význam má lokální 3D intenzitní informace získaná z filtrovaných dat.

Celá práce vznikala v rámci spolupráce Ústavu biomedicínského inženýrství FEKT VUT s firmou Philips Healthcare. Případné využití výstupů této práce třetí osobou je nutné zprostředkovat autorem práce.

Použité zdroje

- [1] CELENK, Cetin a Peruze CELENK. Bone Density Measurement Using Computed Tomography, *Computed Tomography – Clinical Applications*. InTech, 2012. DOI: 10.5772/22884. ISBN 978-953-307-378-1. Dostupné také z: <http://www.intechopen.com/books/computed-tomography-clinical-applications/bone-density-measurement-using-computed-tomography>
- [2] HOLLAND, Elizabeth A. a Lee F. ROGERS. Osteoporosis: Impact on the elderly, societal concerns, and the role of radiology. *Current Problems in Diagnostic Radiology*. 1989, **13**(2), 45-61. DOI: 10.1016/0363-0188(89)90007-8. ISSN 03630188. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/0363018889900078>
- [3] TAY, Wei-Liang, Chee-Kong CHUI, Sim-Heng ONG a Alvin Choong-Meng NG. Osteoporosis Screening Using Areal Bone Mineral Density Estimation from Diagnostic CT Images. *Academic Radiology*. 2012, **19**(10), 1273-1282. DOI: 10.1016/j.acra.2012.05.017. ISSN 10766332. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S1076633212003248>
- [4] BODEN, Scott D., David J. GOODENOUGH, Charles D. STOCKHAM, Eugene JACOBS, Thomas DINA a Robert M. ALLMAN. Precise measurement of vertebral bone density using computed tomography without the use of an external reference phantom. *Journal of Digital Imaging*. 1989, **2**(1), 31-38. DOI: 10.1007/BF03168013. ISSN 0897-1889. Dostupné také z: <http://link.springer.com/10.1007/BF03168013>
- [5] HABASHY, Alexander H., Xiaowei YAN, J. Keenan BROWN, Xiaoping XIONG a Sue C. KASTE. Estimation of bone mineral density in children from diagnostic CT images: A comparison of methods with and without an internal calibration standard. *Bone*. 2011, **48**(5), 1087-1094. DOI: 10.1016/j.bone.2010.12.012. ISSN 87563282. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S8756328210020983>
- [6] GUDMUNDSDOTTIR, H., B. JONSDOTTIR, S. KRISTINSSON, A. JOHANNESSON, D. GOODENOUGH a G. SIGURDSSON. Vertebral bone density in icelandic women using quantitative computed tomography without an external reference phantom. *Osteoporosis International*. 1993, **3**(2), 84-89. DOI: 10.1007/BF01623378. ISSN 0937-941x. Dostupné také z: <http://link.springer.com/10.1007/BF01623378>
- [7] JING ZHANG, CHYE-HWANG YAN, CHEE-KONG CHUI a S H ONG. Accurate Measurement of Bone Mineral Density Using Clinical CT Imaging With Single Energy Beam Spectral Intensity Correction. *IEEE Transactions on Medical Imaging*. 2010, **29**(7), 1382-1389. DOI: 10.1109/TMI.2010.2045767. ISSN 0278-0062. Dostupné také z: <http://ieeexplore.ieee.org/document/5431002/>

- [8] ZHAO, Kai, Jianguo LIU, Kunio DOI, et al. An automatic method for measurement of vertebral bone density based on QCT without an external reference phantom. *SPIE*. 2009. DOI: 10.1117/12.830955. Dostupné také z: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.830955>
- [9] BOLOTIN, Hh, H SIEVÄNEN a JI GRASHUIS. Patient-Specific DXA Bone Mineral Density Inaccuracies: Quantitative Effects of Nonuniform Extraosseous Fat Distributions. *Journal of Bone and Mineral Research*. 2003, **18**(6), 1020-1027. DOI: 10.1359/jbmr.2003.18.6.1020. ISSN 08840431. Dostupné také z: <http://doi.wiley.com/10.1359/jbmr.2003.18.6.1020>
- [10] MUELLER, Dirk K., Alex KUTSCHERENKO, Hans BARTEL, Alain VLASSENBROEK, Petr OUREDNICEK a Joachim ERCKENBRECHT. Phantom-less QCT BMD system as screening tool for osteoporosis without additional radiation. *European Journal of Radiology*. 2011, **79**(3), 375-381. DOI: 10.1016/j.ejrad.2010.02.008. ISSN 0720048x. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0720048X10000744>
- [11] RHO, J.Y., M.C. HOBATHO a R.B. ASHMAN. Relations of mechanical properties to density and CT numbers in human bone. *Medical Engineering*. 1995, **17**(5), 347-355. DOI: 10.1016/1350-4533(95)97314-F. ISSN 13504533. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/135045339597314F>
- [12] AUBREY, J., N. ESFANDIARI, V. E. BARACOS, F. A. BUTEAU, J. FRENETTE, C. T. PUTMAN a V. C. MAZURAK. Measurement of skeletal muscle radiation attenuation and basis of its biological variation. *Acta Physiologica*. 2014, **210**(3), 489-497. DOI: 10.1111/apha.12224. ISSN 17481708. Dostupné také z: <http://doi.wiley.com/10.1111/apha.12224>
- [13] JAN, J. *Medical image processing, reconstruction and restoration: concepts and methods*. Boca Raton: Taylor & Francis, 2006. 730 s. ISBN 0-8247-5849-8.
- [14] WALEK, Petr, Martin LAMOŠ a Jiří JAN. *Analýza biomedicínských obrazů: Počítačová cvičení*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2013, 138 s. ISBN 978-80-214-4792-9.
- [15] LIU JIANZHUANG, LI WENQING a TIAN YUPENG. Automatic thresholding of gray-level pictures using two-dimension Otsu method. In: *1991 International Conference on Circuits and Systems*. IEEE, 1991, s. 325-327. DOI: 10.1109/CICCAS.1991.184351. Dostupné také z: <http://ieeexplore.ieee.org/document/184351/>
- [16] SEZGIN, Mehment a Bülent SANKUR. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*.

- 2004, **13**(1), 146-148. DOI: 10.1117/1.1631315. ISSN 1017-9909. Dostupné také z: <http://electronicimaging.spiedigitallibrary.org/article.aspx?doi=10.1117/1.1631315>
- [17] OTSU, Nobuyuki. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*. 1979, **9**(1), 62-66. DOI: 10.1109/TSMC.1979.4310076. ISSN 0018-9472. Dostupné také z: <http://ieeexplore.ieee.org/document/4310076/>
- [18] KAPUR, J.N., P.K. SAHOO a A.K.C. WONG. A new method for gray-level picture thresholding using the entropy of the histogram. *Computer Vision, Graphics, and Image Processing*. 1985, **29**(3), 273-285. DOI: 10.1016/0734-189X(85)90125-2. ISSN 0734189x. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/0734189X85901252>
- [19] RIDLER, T.W. Picture Thresholding Using an Iterative Selection Method. *IEEE Transactions on Systems, Man, and Cybernetics*. 1978, **8**(8), 630-632. DOI: 10.1109/TSMC.1978.4310039. ISSN 0018-9472.
- [20] PETROU, Maria a Costas PETROU. *Image processing: the fundamentals*. 2nd ed. Chichester: Wiley, 2010, 794 s. ISBN 978-0-470-74586-1.
- [21] ROERDINK, Jos B.T.M. a Arnold MEIJSTER. The Watershed Transform: Definitions, Algorithms and Parallelization Strategies. *Journal Fundamenta Informaticae*. 2000, **41**(1,2,), 187-228.
- [22] ŠALPLACHTA, J. *Texturní analýza nádorových tkání v CT obrazových datech plic..* Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. 62 s. Vedoucí semestrální práce Ing. Roman Jakubiček.
- [23] ŠRÁMEK, J., O. RÁČEK, M. SEDLÁŘ a V. MORNSTEIN. *Získávání a analýza obrazové informace*. LF MU Brno, 2011. [online]. [cit. 2016-12-19]. Dostupné z: <http://www.med.muni.cz/biofyz/Image/ucebnice.pdf>
- [24] MALIK, Jitendra, Serge BELONGIE, Thomas LEUNG a Jianbo SHI. *International Journal of Computer Vision*. **43**(1), 7-27. DOI: 10.1023/A:1011174803800. ISSN 09205691. Dostupné také z: <http://link.springer.com/10.1023/A:1011174803800>
- [25] HARALICK, R.M. Statistical and structural approaches to texture. *Proceedings of the IEEE*. 1979, **67**(5), 786-804. DOI: 10.1109/PROC.1979.11328. ISSN 0018-9219. Dostupné také z: <http://ieeexplore.ieee.org/document/1455597/>
- [26] DONGXIAO, Z. *Texture Analysis and Synthesis using a Generic Markov-Gibbs Image Model: Texture analysis and its applications*. 2006 [online]. [cit. 2016-12-19]. Dostupné z: <http://www.cs.auckland.ac.nz/~georgy/research/texture/thesis-html/node7.html>

- [27] TUCERYAN, M., JAIN A. K. *Handbook of Pattern Recognition and Computer Vision: Texture analysis*. USA: World Scientific Publishing Co. 1993. s. 235-276. ISBN:981-02-1136-8.
- [28] AMATERKA, A. a M. STRZELECKI. *Texture Analysis Methods – A Review*. Technical University of Lodz, Institute of Electronics, COST B11 report, Brussels, 1998.
- [29] SRINIVASAN, G. N. a G. SHOBHA. Statistical Texture Analysis. In: *Proceedings of World Academy of Science, Engineering and Technology*. 2008, **36**(12). ISSN 2070-3740.
- [30] HARALICK, Robert M., K. SHANMUGAM a Its'Hak DINSTEIN. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*. 1973, **SMC-3**(6), 610-621. DOI: 10.1109/TSMC.1973.4309314. ISSN 0018-9472. Dostupné také z: <http://ieeexplore.ieee.org/document/4309314/>
- [31] XIAOOU TANG. Texture information in run-length matrices. *IEEE Transactions on Image Processing*. 7(11), 1602-1609. DOI: 10.1109/83.725367. ISSN 10577149. Dostupné také z: <http://ieeexplore.ieee.org/document/725367/>
- [32] RACHIDI, M., A. MARCHADIER, C. GADOIS, E. LESPESSAILLES, C. CHAPPARD a C. L. BENHAMOU. Laws' masks descriptors applied to bone texture analysis: an innovative and discriminant tool in osteoporosis. *Skeletal Radiology*. 2008, **37**(6), 541-548. DOI: 10.1007/s00256-008-0463-2. ISSN 0364-2348. Dostupné také z: <http://link.springer.com/10.1007/s00256-008-0463-2>
- [33] TAJI, T. S. a D. V. GORE. Overview of Texture Image Segmentation Techniques. *International Journal of Advanced Research in Computer Science and Software Engineering*. 2013, **3**(12). ISSN: 2277 128X.
- [34] ZHANG, Dengsheng a Guojun LU. Review of shape representation and description techniques. *Pattern Recognition*. 2004, **37**(1), 1-19. DOI: 10.1016/j.patcog.2003.07.008. ISSN 00313203. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0031320303002759>
- [35] HOLČÍK, Jiří. *Analýza a klasifikace dat*. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-793-2.
- [36] Kozumplík, J., Provazník, I.: *Umělá inteligence v medicíně*. Elektronická skripta. ÚBMI FEKT VUT v Brně, Brno, 2007.
- [37] HARUŠTIAKOVÁ, Danko, Jiří JARKOVSKÝ, Simona LITTNEROVÁ a Ladislav DUŠEK. *Vícerozměrné statistické metody v biologii*. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-791-8.
- [38] KOZUMPLÍK, J. *Umělá inteligence v medicíně: Shluková analýza*. Ústav biomedicínského inženýrství, Vysoké učení technické v Brně. 2014 [online]. [cit. 2016-12-15]. Dostupné z:

https://www.vutbr.cz/elearning/file.php/148627/prednasky2014/AUIN_03_shlukova_analyza-1.pdf

[39] JARKOVSKÝ, J. a S. LITTNEROVÁ. *Pokročilé statistické metody: Shluková analýza*. Ústav biomedicínského inženýrství, Vysoké učení technické v Brně. 2011.

[40] AKUME, D. a G.-W. WEBER, Cluster algorithms: theory and methods. *Journal of Computational Technologies*, 2002, 7(1), s. 15-27. ISBN: 1560-7534.

[41] *A Tutorial on Clustering Algorithms: K-Means Clustering*. [online]. [cit. 2016-12-17]. Dostupné z:

http://home.deib.polimi.it/matteucc/Clustering/tutorial_html/kmeans.html#macqueen

[42] KOZUMPLÍK, J. *Umělá inteligence v medicíně: Shluková analýza (2)*. Ústav biomedicínského inženýrství, Vysoké učení technické v Brně. 2014[online]. [cit. 2016-12-17]. Dostupné z:

https://www.vutbr.cz/elearning/file.php/148627/prednasky2014/AUIN_03_shlukova_analyza-2.pdf

[43] VASSILVITSKII, S. a S. VENKATASUBRAMANIAN. *New developments in the theory of clustering*. [online]. [cit. 2016-12-17]. Dostupné z:

<http://theory.stanford.edu/~sergei/slides/kdd10-thclust.pdf>

[44] WEI, Yong, Xiuping TAO, Bin XU a Arend P. CASTELEIN. Paraspinal Muscle Segmentation in CT Images Using GSM-Based Fuzzy C-Means Clustering. *Journal of Computer and Communications*. 2014, 02(09), 70-77. DOI: 10.4236/jcc.2014.29010. ISSN 2327-5219. Dostupné také z:

<http://www.scirp.org/journal/PaperDownload.aspx?DOI=10.4236/jcc.2014.29010>

[45] BREIMAN, Leo. Random Forests. *Machine Learning*. 45(1), 5-32. DOI: 10.1023/A:1010933404324. ISSN 08856125. Dostupné také z:

<http://link.springer.com/10.1023/A:1010933404324>

[46] LEO BREIMAN .. [ET AL.]. *Classification and regression trees*. Repr. New York, N.Y: Chapman, 1993. ISBN 978-041-2048-418.

[47] BUREŠ, L. a P. ZIMMERMANN, *Metody Počítačového vidění – 9. přednáška: Strojové učení*. Katedra kybernetiky, Západočeská univerzita v Plzni. 2014 [online]. [cit. 2017 05-06]. Dostupné z:

http://www.kky.zcu.cz/uploads/courses/mpv/09/lesson09_materialy.pdf

[48] LOH, Wei-Yin. Classification and regression trees: ČSN EN ISO 3166 (97 1002). *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. 2011, 1(1), 14-23. DOI: 10.1002/widm.8. ISSN 19424787. Dostupné také z:

<http://doi.wiley.com/10.1002/widm.8>

[49] *KDAG: Ensemble Learning* [online]. [cit. 2017-05-06]. Dostupné z:

<https://kgpdag.wordpress.com/>

- [50] KENDALL, Florence Peterson. *Muscles: testing and function with posture and pain*. 5th ed. Baltimore, MD: Lippincott Williams, c2005. ISBN 07-817-4780-5.
- [51] MANCAS, Matei, Edward R. DOUGHERTY, Jaakko T. ASTOLA, Bernard GOSSELIN, Benoit MACQ a Karen O. EGIAZARIAN. Segmentation using a region-growing thresholding.,388-. DOI: 10.1117/12.587995. Dostupné také z: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.587995>
- [52] WEI, Yong, Bin XU, Xiuping TAO a JUNFENG QU. Paraspinal muscle segmentation in CT images using a single atlas. *2015 IEEE International Conference on Progress in Informatics and Computing (PIC)*. IEEE, 2015, 211-215. DOI: 10.1109/PIC.2015.7489839. ISBN 978-1-4673-8086-7. Dostupné také z: <http://ieeexplore.ieee.org/document/7489839/>
- [53] CHENYANG XU a J.L. PRINCE. Snakes, shapes, and gradient vector flow. *IEEE Transactions on Image Processing*. 7(3), 359-369. DOI: 10.1109/83.661186. ISSN 10577149. Dostupné také z: <http://ieeexplore.ieee.org/document/661186/>
- [54] PEDNEKAR, A., A.N. BANDEKAR, I.A. KAKADIARIS a M. NAGHAVI. Automatic Segmentation of Abdominal Fat from CT Data. *2005 Seventh IEEE Workshops on Applications of Computer Vision (WACV/MOTION'05) - Volume 1*. IEEE, 2005, , 308-315. DOI: 10.1109/ACVMOT.2005.31. ISBN 0-7695-2271-8. Dostupné také z: <http://ieeexplore.ieee.org/document/4129496/>
- [55] ROMERO, D., J.C. RAMIREZ a A. MARMOL. Quanification of subcutaneous and visceral adipose tissue using CT. *IEEE International Workshop on Medical Measurement and Applications, 2006. MeMea 2006*. IEEE, 2006, , 128-133. DOI: 10.1109/MEMEA.2006.1644478. ISBN 1-4244-0253-0. Dostupné také z: <http://ieeexplore.ieee.org/document/1644478/>
- [56] YOSHIZUMI, Tohru, Tadashi NAKAMURA, Mitsukazu YAMANE, et al. Abdominal Fat: Standardized Technique for Measurement at CT. *Radiology*. 1999, **211**(1), 283-286. DOI: 10.1148/radiology.211.1.r99ap15283. ISSN 0033-8419. Dostupné také z: <http://pubs.rsna.org/doi/10.1148/radiology.211.1.r99ap15283>
- [57] UDUPA, Jayaram K. a Supun SAMARASEKERA. Fuzzy Connectedness and Object Definition: Theory, Algorithms, and Applications in Image Segmentation. *Graphical Models and Image Processing*. 1996, **58**(3), 246-261. DOI: 10.1006/gmip.1996.0021. ISSN 10773169. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S1077316996900210>
- [58] ZHAO, Binsheng, Jane COLVILLE, John KALAIGIAN, Sean CURRAN, Li JIANG, Peter KIJEWski a Lawrence H. SCHWARTZ. Automated Quantification of Body Fat Distribution on Volumetric Computed Tomography. *Journal of Computer Assisted Tomography*. 2006, **30**(5), 777-783. DOI: 10.1097/01.rct.0000228164.08968.e8. ISSN 0363-8715. Dostupné také z:

<http://content.wkhealth.com/linkback/openurl?sid=WKPTLP:landingpage>

- [59] JARKOVSKÝ, J. a S. LITTNEROVÁ. *Pokročilé statistické metody: Ordinační analýzy – principy redukce dimenzionality*. Ústav biomedicínského inženýrství, Vysoké učení technické v Brně. 2011.
- [60] JARKOVSKÝ, J. *Biostatistika: Statistika ve vědecké praxi*. Institut biostatistiky a analýz, Masarykova univerzita. 2013
- [61] SHLENS, J. *A tutorial on principal component analysis*, CoRR abs/1404.1100. 2014
- [62] MELOUN, Milan, Jiří MILITKÝ a Martin HILL. *Počítačová analýza vícerozměrných dat v příkladech*. Praha: Academia, 2005. ISBN 80-200-1335-0.
- [63] JARKOVSKÝ, J. a S. LITTNEROVÁ. *Pokročilé statistické metody: Diskriminační analýza*. Ústav biomedicínského inženýrství, Vysoké učení technické v Brně. 2011.
- [64] COUPE, P., P. YGER, S. PRIMA, P. HELLIER, C. KERVRANN a C. BARILLOT. An Optimized Blockwise Nonlocal Means Denoising Filter for 3-D Magnetic Resonance Images. *IEEE Transactions on Medical Imaging*. 2008, 27(4), 425-441. DOI: 10.1109/TMI.2007.906087. ISSN 0278-0062. Dostupné také z: <http://ieeexplore.ieee.org/document/4359947/>
- [65] BUADES, A., B. COLL a J.-M. MOREL. A Non-Local Algorithm for Image Denoising. In: *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. IEEE, 2005, s. 60-65. DOI: 10.1109/CVPR.2005.38. ISBN 0-7695-2372-2. Dostupné také z: <http://ieeexplore.ieee.org/document/1467423/>
- [66] IMMERKÆR, John. Fast Noise Variance Estimation. *Computer Vision and Image Understanding*. 1996, 64(2), 300-302. DOI: 10.1006/cviu.1996.0060. ISSN 10773142. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S1077314296900600>
- [67] JARKOVSKÝ, J. a S. LITTNEROVÁ. *Smysl a cíle vícerozměrné analýzy dat a modelování, vícerozměrné statistické rozdělení a testy*. Ústav biomedicínského inženýrství, Vysoké učení technické v Brně. 2011.
- [68] JARKOVSKÝ, J. a S. LITTNEROVÁ. *Pokročilé statistické metody: Stochastické modelování s binárním endpointem*. Ústav biomedicínského inženýrství, Vysoké učení technické v Brně. 2011.
- [69] PHILIPS, C. a D. LI, cooc3d. [online]. [cit. 2017-05-07]. Dostupné z: <http://www.mathworks.com/matlabcentral/fileexchange/19058-cooc3d>
- [70] WEI, X., grayrlmatrix. [online]. [cit. 2017-05-07]. Dostupné z: http://www.mathworks.com/matlabcentral/fileexchange/17482-gray-level-run-length-matrix-toolbox?s_tid=srchtitle

- [71] UPPULURI, A., GLCM_Features4. [online]. [cit. 2017-05-07]. Dostupné z: <http://www.mathworks.com/matlabcentral/fileexchange/22354-glcm-features4-m--vectorized-version-of-glcm-features1-m--with-code-changes->
- [72] WEI, X., grayrlprops. [online]. [cit. 2017-05-07]. Dostupné z: http://www.mathworks.com/matlabcentral/fileexchange/17482-gray-level-run-length-matrix-toolbox?s_tid=srchtitle
- [73] *Structural Brain Mapping Group: Download* [online]. [cit. 2016-09-08]. Dostupné z: <http://dbm.neuro.uni-jena.de/vbm/download/>

Seznam zkratek

BMC	Bone mineral content – obsah kostních minerálů
BMD	Bone mineral density – minerální kostní denzita
CART	Classification and Regresion Tree – mechanismus tvorby klasifikačních a regresních stromů
CT	Computed tomography – výpočetní rentgenová tomografie
DICOM	The digital imaging and communication in medicine – medicínský datový standard
DXA	Dual-energy X-ray absorptiometry – duální rentgenová absorpciometrie
GLCM	Gray level co-occurrence matrix – matice současného výskytu
GLRLM	Gray level run-length matrix – matice délky běhů
GSM	Gray space map – šedotónová prostorová mapa
GVF	Gradient vector flow – externí síla v rámci SNAKE algoritmu
ICP	Iterative closest point – algoritmus uplatňující se v rámci metod registrace modelu
NLM	Non-local means – algoritmus pro redukci šumu
PCA	Principal component analysis – analýza hlavních komponent
QCT	Quantitative computed tomography – kvantitativní výpočetní rentgenová tomografie
UPGMA	Unweighted Pair Group Method with Arithmetic Mean – metoda využívaná pro hierarchickou shlukovou analýzu – metoda průměrů

A. Přílohy

Tabulka A-1: Seznam počítaných 3D texturních příznaků (198 pro příznaků pro voxel).

Stat. m. I. řádu	1.	Lokální průměr	Stat. m. II. řádu: Run-length matice	24.	Short Run Emphasis (SRE)
	2.	Lokální směrodatná odchylka		25.	Long Run Emphasis (LRE)
	3.	Průměrná lokální směrodatná odchylka		26.	Gray-Level Nonuniformity (GLN)
	4.	Lokální rozptyl		27.	Run Length Nonuniformity (RLN)
	5.	Lokální špičatost		28.	Run Percentage (RP)
	6.	Lokální šikmost		29.	Low Gray-Level Run Emphasis (LGRE)
	7.	Lokální entropie		30.	High Gray-Level Run Emphasis (HGRE)
Stat.m. II. řádu: Co-occurrence matice	8.	Energie		31.	Short Run Low Gray-Level Emphasis (SRLGE)
	9.	Entropie		32.	Short Run High Gray-Level Emphasis (SRHGE)
	10.	Korelace		33.	Long Run Low Gray-Level Emphasis (LRLGE)
	11.	Kontrast		34.	Long Run High Gray-Level Emphasis (LRHGE)
	12.	Homogenita	Spektrální analýza	35.	Výkon – st. složka + v. n. kmitočty
	13.	Normalizovaný inverzní diferenční moment		36.	Výkon – velmi nízké kmitočty
	14.	Maximální pravděpodobnost		37.	Výkon – středně nízké kmitočty
	15.	Diferenční entropie		38.	Výkon – nízké kmitočty
	16.	Průměr součtu		39.	Výkon – střední kmitočty
	17.	Entropie součtu		40.	Výkon – vysoké kmitočty
	18.	Rozptyl součtu		41.	Relativní výkon st. složka + v. n. kmitočty
	19.	Rozptyl		42.	Relativní výkon – velmi nízké kmitočty
	20.	Rozptyl rozdílu		43.	Relativní výkon – středně nízké kmitočty
	21.	Entropie rozdílu		44.	Relativní výkon – nízké kmitočty
	22.	Informační rozsah korelace 1		45.	Relativní výkon – střední kmitočty
	23.	Informační rozsah korelace 2		46.	Relativní výkon – vysoké kmitočty
			Mikrotexturní analýza	47.-198.	Lawsovy 3D masky o hraně 3 (27 příznaků) a 5 (125 příznaků)

Tabulka A-2: Přehled stanovených specifických jasových intervalů použitých v rámci globálního prahování interních kalibračních tkání na základě filtrovaných dat.

	Paraspinální sval		Podkožní tuková tkáň	
	Nativní data	Kontrastní data	Nativní data	Kontrastní data
Specifický interval [HU]	(-6; 148)	(11; 166)	(-143; -74)	(-150; -67)

Tabulka A-3: Nalezené optimální nastavení pro výpočet matic současného výskytu a matic délky běhů na základě filtrovaných dat.

	Nativní data	Kontrastní data
Matrice současného výskytu	vzdálenost: 2; směr: 90° v ose z (přímo vzhůru)	vzdálenost: 2; směr: 90° v ose z (přímo vzhůru)
Matrice délky běhů	směr: 0° (vodorovně)	směr: 0° (vodorovně)

Tabulka A-4: Přehled neredundantních 3D texturních příznaků z jednotlivých sekcí texturní analýzy pro filtrovaná nativní i kontrastní data.

	Nativní data	Kontrastní data
Statistické metody I. řádu	Lokální průměr a entropie	Lokální průměr
Statistické metody II. řádu	Suma průměrů	Korelace
Spektrální analýza	-	-
Mikrotexturní analýza	-	-

Tabulka A-5: Přehled stanovených charakteristik interních kalibračních tkání pro filtrovaná data (modus, medián, průměr, směrodatná odchylka).

	Nativní data	Kontrastní data
Paraspinální sval	(45; 46; 47,53; 30,93)	(63; 59; 59,99; 28,36)
Podkožní tuková tkáň	(-97; -99; -99,90; 14,75)	(-95; -98; -99,16; 17,96)

Tabulka A-6: Výsledky testovaných přístupů na testovací databázi kontrastních dat.

	Globální prahování	Texturní analýza + k-means	Náhodný les
Senzitivita sval	0,78	0,72	0,70
Senzitivita tuk	0,73	0,93	0,52
DSC sval	0,29	0,28	0,46
DSC tuk	0,39	0,42	0,57
Celková úspěšnost [%]	42,11	39,84	75,70

Tabulka A-7: Výsledky testovaných přístupů s využitím redukce šumu ve vstupních datech na databázi nativních dat.

	Globální prahování	Texturní analýza + k-means	Náhodný les
Senzitivita sval	0,82	0,87	0,87
Senzitivita tuk	0,78	0,99	0,91
DSC sval	0,36	0,34	0,43
DSC tuk	0,44	0,37	0,71
Celková úspěšnost [%]	52,43	34,87	71,14

Tabulka A-8: Přínos redukce šumu ve vstupních datech pro výsledky testovaných přístupů na databázi nativních dat.

	Globální prahování	Texturní analýza + k- means	Náhodný les
Senzitivita sval	0,00	0,00	0,09
Senzitivita tuk	0,02	0,00	0,07
DSC sval	0,05	0,00	0,03
DSC tuk	0,08	-0,01	0,08
Celková úspěšnost [%]	10,77	-1,78	2,37

Tabulka A-9: Výsledky testovaných přístupů s využitím redukce šumu ve vstupních datech na databázi kontrastních dat.

	Globální prahování	Texturní analýza + k- means	Náhodný les
Senzitivita sval	0,71	0,79	0,83
Senzitivita tuk	0,81	0,99	0,88
DSC sval	0,31	0,31	0,51
DSC tuk	0,52	0,41	0,79
Celková úspěšnost [%]	54,59	37,69	79,52

Tabulka A-10: Přínos redukce šumu ve vstupních datech pro výsledky testovaných přístupů na databázi kontrastních dat.

	Globální prahování	Texturní analýza + k-means	Náhodný les
Senzitivita sval	-0,07	0,07	0,13
Senzitivita tuk	0,08	0,06	0,36
DSC sval	0,02	0,03	0,05
DSC tuk	0,13	-0,01	0,22
Celková úspěšnost [%]	12,48	-2,15	3,82

Tabulka A-11: Výsledky testovaných přístupů s využitím anatomické informace o lokalizaci interních kalibračních tkání na databázi nativních dat.

	Globální prahování	Texturní analýza + k-means	Náhodný les
Senzitivita sval	0,82	0,86	0,76
Senzitivita tuk	0,73	0,98	0,80
DSC sval	0,53	0,52	0,63
DSC tuk	0,46	0,55	0,77
Celková úspěšnost [%]	50,80	48,58	75,37

Tabulka A-12: Přínos využití anatomické informace o lokalizaci interních kalibračních tkání pro výsledky testovaných přístupů na databázi nativních dat.

	Globální prahování	Texturní analýza + k- means	Náhodný les
Senzitivita sval	0,00	-0,01	-0,02
Senzitivita tuk	-0,03	-0,01	-0,04
DSC sval	0,22	0,18	0,23
DSC tuk	0,10	0,17	0,14
Celková úspěšnost [%]	9,14	11,93	6,60

Tabulka A-13: Výsledky testovaných přístupů s využitím anatomické informace o lokalizaci interních kalibračních tkání na databázi kontrastních dat.

	Globální prahování	Texturní analýza + k- means	Náhodný les
Senzitivita sval	0,78	0,73	0,69
Senzitivita tuk	0,73	0,94	0,53
DSC sval	0,54	0,52	0,61
DSC tuk	0,41	0,49	0,59
Celková úspěšnost [%]	50,76	49,78	71,08

Tabulka A-14: Přínos využití anatomické informace o lokalizaci interních kalibračních tkání pro výsledky testovaných přístupů na databázi kontrastních dat.

	Globální prahování	Texturní analýza + k- means	Náhodný les
Senzitivita sval	0,00	0,01	-0,01
Senzitivita tuk	0,00	0,01	0,01
DSC sval	0,25	0,24	0,15
DSC tuk	0,02	0,07	0,02
Celková úspěšnost [%]	8,65	9,94	-4,62

Tabulka A-15: Výsledky testovaných přístupů s využitím anatomické informace o lokalizaci interních kalibračních tkání v kombinaci s redukcí šumu na databázi kontrastních dat.

	Globální prahování	Texturní analýza + k- means	Náhodný les
Senzitivita sval	0,72	0,79	0,83
Senzitivita tuk	0,77	0,99	0,90
DSC sval	0,56	0,54	0,69
DSC tuk	0,55	0,49	0,84
Celková úspěšnost [%]	59,61	49,66	78,09

Tabulka A-16: Přínos využití anatomické informace o lokalizaci interních kalibračních v kombinaci s redukcí šumu ve vstupních datech pro výsledky testovaných přístupů na databázi kontrastních dat.

	Globální prahování	Texturní analýza + k- means	Náhodný les
Senzitivita sval	-0,06	0,07	0,13
Senzitivita tuk	0,04	0,06	0,38
DSC sval	0,27	0,26	0,23
DSC tuk	0,16	0,07	0,27
Celková úspěšnost [%]	17,50	9,82	2,39

Tabulka A-17: Přínos využití neredundantního vektoru texturních příznaků pro klasifikaci algoritmem náhodného lesa na testovací databázi nativních dat.

	Intenzita	Intenzita + texturní příznaky	Rozdíl
Senzitivita sval	0,78	0,76	-0,02
Senzitivita tuk	0,84	0,80	-0,04
DSC sval	0,40	0,40	0
DSC tuk	0,63	0,68	0,05
Celková úspěšnost [%]	68,77	71,87	3,10

Tabulka A-18: Přínos využití neredundantního vektoru texturních příznaků pro klasifikaci algoritmem náhodného lesa na testovací databázi kontrastních dat.

	Intenzita	Intenzita + texturní příznaky	Rozdíl
Senzitivita sval	0,70	0,69	-0,01
Senzitivita tuk	0,52	0,31	-0,21
DSC sval	0,46	0,49	0,03
DSC tuk	0,57	0,39	-0,18
Celková úspěšnost [%]	75,70	76,41	0,71