

VŠB – Technical University of Ostrava
Faculty of Electrical Engineering and Computer
Science

Modeling and extraction of the articular
cartilage

PHD THESIS

2017

Ing. Jan Kubíček

Prohlášení

Prohlašuji, že svou disertační práci na téma „Modelování a extrakce oblasti artikulární chrupavky“ jsem vypracoval samostatně a uvedl jsem veškerou odbornou literaturu, ze které jsem čerpal.

V Ostravě dne 5. listopadu 2017

.....
Ing. Jan Kubíček

Poděkování

Tato práce byla realizována za podpory několika lidí, kterým bych rád poděkoval. Rád bych touto cestou poděkoval za odborné vedení během mého dokrorského studia mému školiteli doc. Marku Penhakerovi. Rovněž bych rád poděkoval, MUDr. Michalu Kodajovi za poskytnutí klinických dat artikulárních chrupavek. Dále bych rád poděkoval své rodině a všem svým přátelům za podporu během řešení mé disertační práce.

Abstrakt

Tato disertační práce se zabývá modelováním a extrakcí artikulární chrupavky z obrazových dat MR (magnetické rezonance). V oblasti klinické diagnostiky artikulárních chrupavek je stěžejní přesná lokalizace chrupavky s ohledem na patologické procesy, které jsou často obtížně hodnotitelné, neboť jejich manifestace oproti fyziologické chrupavce je nekontrastní. Hodnocení chrupavek je často ovlivněno subjektivní chybou a je závislé na zkušenostech hodnotícího lékaře. Tato práce se zabývá designem multiregionální segmentační metodologie, která se opírá o dvoufázovou klasifikaci pixelů. V prvním kroku je řešen návrh jasové segmentační procedury, aproximující jednotlivé obrazové regiony pomocí posloupnosti fuzzy trojúhelníkovitých funkcí členství. Lokalizace těchto funkcí je řízena ABC (Artificial Bee Colony) algoritmem, který reprezentuje genetický evoluční proces. Druhá část metodologie se zabývá lokální agregační procedurou, která bere v úvahu prostorové relace pixelů a umožňuje modifikovat členskou funkci jasové klasifikace. Značnou výhodou takového systému je robustnost vůči šumovým pixelům a artefaktům, které v určité míře bývají přítomny v MR obrazových datech. Výstupem segmentační procedury je regionální model artikulární chrupavky, který spolehlivě reflektuje fyziologickou oblast artikulární chrupavky od lokací, kde dochází již k rané ztrátě chrupavky, která je obtížněji detekovatelná z nativních MR záznamů. Navrhovaná metoda byla rovněž testována na syntetických variabilních zdrojích obrazového šumu.

Klíčová slova

Kolenní chrupavka, magnetická rezonance, osteoartritida, chondromalacie, soft prahování, lokální agregace, genetické algoritmy, Artificial Bee Colony.

Abstract

This dissertation thesis deals with the modeling and extraction of the articular cartilage from the MR (magnetic resonance) image data. In an area of the articular cartilage clinical diagnostic, a precise localization of the articular cartilage is essential with regard to the pathological processes which are often badly evaluable due to their manifestation is non contrast in comparison with the physiological cartilage. The cartilage assessment is often affected by the subjective error, and it is depended on physician's experience. This work is focused on a design of the multiregional segmentation methodology which is based on two-phase pixel classification. In the first step, a design of the brightness segmentation procedure is figured out approximating individual image regions by a sequence of the fuzzy triangular membership functions. A localization of those functions is driven by the ABC (Artificial Bee Colony) algorithm representing a genetic evolutionary process. The second part of the methodology deals with the local aggregation procedure taking into account spatial pixels relationships, and allows for a modification of the brightness classification membership function. A substantial benefit of such system is robustness against the noise pixels and artefacts which are presented in the MR image data. Output of the segmentation procedure is a regional model of the articular cartilage which reliably reflects the articular cartilage physiological area from locations of early cartilage loss. Such changes are badly detectable from the native MR data. The proposed method has been also tested on synthetic variable sources of the image noise.

Keywords

Articular cartilage, magnetic resonance, osteoarthritis, chondromalacia, soft thresholding, local aggregation, genetic algorithms, Artificial Bee Colony.

Obsah

Seznam zkratk	8
Seznam obrázků	10
Seznam tabulek	18
Úvod	19
1 Artikulární chrupavka	21
1.1 Hyalinní chrupavka	21
1.2 Morfologie kloubní chrupavky	21
1.3 Cévní zásobení kloubní chrupavky	23
1.4 Vlastnosti kloubní chrupavky	23
1.5 Femoropatelární skloubení	23
1.5.2 Postižení femoropatelárního kloubu	25
2 Vyšetřovací metody artikulárních chrupavek	27
2.1 Nativní snímky	27
2.2 Ultrasonografie	28
2.3 Magnetická rezonance (MR)	28
2.3.1 Morfologické hodnocení	29
2.3.2 MR techniky s potlačením tuku	30
2.3.3 2D SE a rychlé SE zobrazování	32
2.3.4 3D rychlé SE zobrazování	34
2.3.5 SPGR zobrazování	35
2.3.6 DEFT zobrazování	36
2.3.7 DESS zobrazování	37
2.3.8 bSSFP zobrazování	38
2.3.9 VIPR zobrazování	39
2.3.10 SPACE zobrazování	40
2.3.11 Kompozitní zobrazování chrupavky	40
3 Segmentační metody artikulárních chrupavek z MR	48
3.1 Segmentační metody kolenního kloubu	48
3.2 Přehled	48
3.3 Manuální segmentace artikulárních chrupavek	48
3.4 Automatická segmentace artikulárních chrupavek	49

3.5	Validační metrika	49
3.6	Poloautomatická segmentace artikulárních chrupavek	50
3.6.1	Intensity-based segmentace	50
3.6.2	Segmentace na základě detekce hran.....	52
3.6.3	Segmentace využívající minimalizaci energie	55
3.7	Plně automatická segmentace.....	57
3.7.1	Analýza textur	57
3.7.2	Učení s učitelem	58
3.7.3	Statistické modely	60
3.7.4	Segmentace na základě Houghovy transformace a adaptivní Cannyho detekce	65
3.7.5	Segmentace na základě rozpoznávání vzorů	67
4	Modelování morfologické struktury artikulárních chrupavek.....	69
4.1	Multiregionální fuzzy prahování	70
4.1.1	Motivace a účel.....	70
4.2	Předzpracování MR obrazových dat	72
4.3	Segmentační algoritmus využívající soft prahování	74
4.3.1	Jasová klasifikace pixelů	75
4.3.2	Proces extrakce centroidů.....	78
4.3.3	Algoritmus K means.....	78
4.3.4	Referenční model artikulární chrupavky	79
4.3.5	Geneze ideálního modelu chrupavky	84
4.3.6	Optimalizace fuzzy členských funkcí.....	88
4.3.7	ABC algoritmus využívající modifikovanou fitness funkci	88
4.3.8	Testování optimalizace distribuce fuzzy množin	93
4.3.9	Prostorová segmentace pixelů (agregace)	97
4.3.10	Lokální agregace segmentační procedury	100
4.3.11	Segmentace obrazu.....	104
4.3.12	Kvantitativní komparace a testování	104
5	Geneze a analýza modelu	111
5.1	Segmentační model využívající selekci oblasti zájmu	112
5.1.1	Extrakce artikulární chrupavky	114
6	Závěr	118
	Literatura	121

Publikační činnost autora 134

Seznam zkratek

ADC	Difuzní koeficient
Agg{.}	Agregační funkce
AvAg	Průměrový agregát
BCI	Bone-cartilage interface
BLOKS	Boston-Leeds Osteoarthritis Scoring System
bSSFP	balanced Steady-State Free Precession
$C(S_2 \rightarrow S_1)$	Překrytí segmentace
C_v	Variační koeficient
DEFT	Driven Equilibrium Fourier Transformation
DESS	Double Echo Steady State
dGEMRIC	Delayed gadolinium-enhanced MRI of cartilage
DRF	Discriminative Random Field
DSC	Dice Similarity Coefficient
EB	Syntetické zaměstnané včely
FCM	Fuzzy C means
FLASH	Fast Low-Angle Shot
fit_i	Fitness funkce i-tého řešení
FT-II	Prahování obrazu využívající typ II fuzzy množin
GA	Genetický algoritmus
GMF	Gaussova funkce členství
GRE	Gradientní recall echo sekvence
$g_s\{.\}$	Segmentační metoda
H	Kapurova entropie
$h(I)$	Histogramová funkce
$I(x,y)$	Obrazová funkce
ITS	Iterativní prahovací segmentace
kNN	Technika k-nejbližšího souseda
KOSS	Knee Osteoarthritis Scoring System
L	Počet segmentačních regionů
MASP	Segmentace založená na maximální prostorové pravděpodobnosti
MedAg	Mediánový agregát
MMSE	Střední kvadratická chyba
$M(r)$	Segmentovaný obraz
MR	Magnetická rezonance

MRI	Zobrazování magnetickou rezonancí
r	Pearsonův korelační koeficient
OB	Syntetické vyčkávající včely
$p_i(x; \theta_i)$	Hustota pravděpodobnosti
PD	Proton density sequence
PTS	Pseudo Trapezoid-Shaped function
RI	Rand index
RoI	Region of interest
RTG	Rentgen
SB	Syntetické včely – skauti
SE	Spin echo sekvence
S-FCM	Prostorové fuzzy shlukování
SN	Inicializační populace ABC algoritmu
SNR	Signal-to-Noise Ratio
SSM	Statistical Shape Model
SVM	Support Vector Machine
$T1\rho$	$T1\rho$ relaxační čas (trvání relaxace spinové mřížky v rotačním rámu)
T2	Pulzní MR sekvence
UZV	Ultrazvuk
V	Vrchol trojúhelníkovité funkce
VI	Variace informace
VIPR	Isotropic-voxel radial projection imaging
VoI	Volume of Interest
WORMS	Whole-Organ MR Imaging Score
Ω	Obrazová doména
σ	Směrodatná odchylka
μ	Průměr hodnot
$\mu_i(x)$	Fuzzy funkce členství i^{th} regionu
$\eta(r)$	Sousedství pixelů

Seznam obrázků

- Obrázek 1 Struktura hyalinní chrupavky. (str. 22)
- Obrázek 2 Anatomie kolenního kloubu. (str. 23)
- Obrázek 3 Anatomie pately. (str. 24)
- Obrázek 4 Wibergova-Baumgartlova klasifikace tvaru pately. (str. 24)
- Obrázek 5 Tvarové anomálie češky. (str. 25)
- Obrázek 6 Klasifikace jednotlivých stádií chondromalacie. (str. 26)
- Obrázek 7 Rentgenový snímek artikulární chrupavky: předozadí (a), boční pohled levého kolena (b), axiální snímek pately (c). (str. 27)
- Obrázek 8 Vymezení femorálního a tibiálního rozpětí, které umožňuje výpočet střední šíře kloubní štěrbiny při normalizované vzdálenosti mediálního a laterálního kompartmentu, což je indikováno růžovou linií. Minimální šíře kloubní štěrbiny je žlutou linií ve vertikálním směru. (str. 27)
- Obrázek 9 Nepoškozená chrupavka v UZV obraze. (str. 28)
- Obrázek 10 Chrupavka v UZV obraze, část chondromalacie je indikována šipkou. (str. 28)
- Obrázek 11 Zobrazování artikulární chrupavky MR, ukázka PD sekvence. Celistvost chrupavky je narušena počínající ztrátou chrupavky I. stupně. Tento fenomén je lokalizován blastí zájmu. (str. 29)
- Obrázek 12 (a) Sagitální střední vážený SE obraz s potlačením tuku (TR msec/echo čas [TE] msec=4000/35). Jsou zobrazeny regiony s vysokou signálovou intenzitou kvůli otlačení tuku (hrot šipky). (b) Sagitální střední vážený ‘IDEAL fast water image (TR/TE=4000/35)’ ukazuje cystu, která je indikována šipkou. Tato technika umožňuje lepší diferenciaci tuku a vody. (str. 30)
- Obrázek 13 Časově inverzní obnovený obraz z oblasti kolena, přesně ukazující fokální plně chondrální defekt (šipky) na trochleární drážce. (str. 31)
- Obrázek 14 Sagitální 2D fast SE obraz, získaný na základě různých technik ze stejné kolenní oblasti. (a) T1 – vážený obraz ukazuje slabý kontrast mezi povrchem chrupavky a synoviální tekutinou, značnou nevýhodou je neposkytnutí informace pro přesné posouzení fokálního chrupavčitého defektu (hrot šipky). (b, c) T2 – váhování (b) a vážená protonová denzita. (c) Obraz poskytuje lepší kontrast mezi povrchem chrupavky synoviální tekutinou, umožňující identifikaci plného chrupavčitého defektu (hrot šipky) v mediálním femorálním kondylu. (str. 31)

- Obrázek 15 Axiální 2D T2 vážený rychlý SE obraz, poskytující excelentní reprezentaci fokálních regionů hluboké chrupavčité delaminace (šipky) s vysokým kontrastem mezi chrupavčítým povrchem a synoviální tekutinou. (str. 32)
- Obrázek 16 Axiální 2D T2 vážený rychlý SE obraz s nepotlačením tuku, poskytující excelentní kontrast mezi povrchem chrupavky a synoviální tekutinou, ale chrupavka je nedostatečně reprezentována s nízkou difuzní signálovou intenzitou. Současně je absence kontrastu mezi chrupavkou a kortikální kostí (vlevo). Axiální 2D střední vážený rychlý SE obraz s potlačením tuku poskytuje excelentní kontrast mezi povrchem chrupavky, synoviální tekutinou a subchondrální kostí, také variaci intenzity signálu v průběhu chrupavky (vpravo). (str. 33)
- Obrázek 17 (a) Koronární 3D střední vážený rychlý SE zdrojový obraz získaný s izotropním prostorovým rozlišením, neukazují se abnormality chrupavky. (b, c) Axiální (b) a sagitální (c) obraz získaný přeformátováním koronárního zdrojového obrazu. Manifestace chondrálního defektu (šipka) a trochleární drážky. (str. 34)
- Obrázek 18 Koronární 3D SPRG obraz ukazuje intaktní povrch chrupavky s vysokou intenzitou. Potlačení lipidů poskytuje excelentní kontrast mezi chrupavkou a subchondrální kostí. (str. 35)
- Obrázek 19 (a) Koronární T2 vážený obraz s potlačením tuku ukazuje velké oblasti kompletní ztráty chrupavky v mediální tibiofemorální oblasti s degenerativními lézemi v subchondrální kosti (hrot šipky). Velké osteofyty a mediální extrukce jsou rovněž viditelné. (b) Koronární 3D FLASH obraz přesně reprezentuje oblasti kompletní ztráty chrupavky v mediální části, jako je tomu v obrazu (a). (str. 36)
- Obrázek 20 Sagitální 3D DEFT obraz demonstrující fisury chrupavky (šipka). Defekt je vymezen na základě vysoké signálové intenzity synoviální tekutiny. (str. 37)
- Obrázek 21 Segmentace 3D DESS obrazových dat, získaných v koleni. (a, b v rozdílných plánech) poskytují kvantifikaci chrupavky ve femorálních kondylech (červená a žlutá), tibiální plošiny (tmavě modrá a zelená), trochlea (světle modrá) a patella (fialová). (str. 38)
- Obrázek 22 (a) Sagitální 3D excitace vody, bSSFP zdrojový obraz ukazuje fokální parciální tloušťku defektu chrupavky (šipka) v mediálním femorálním kondylu. (b) Věčtý přeformátovaný obraz ukazuje defekty (šipky). (str. 39)
- Obrázek 23 Sagitální zdroj (a) a koronální přeformátování (b) 3D VIPR-SSFP obrazy vykazují vysoké SNR u chrupavky a vysoký kontrast mezi chrupavkou, synoviální tekutinou a ostatními kloubními strukturami. (str. 39)
- Obrázek 24 3D SPACE zobrazování přesně vymezuje chrupavku v mediálním femorálním kondylu (hrot šipky) a trhlinu posteriálního rohu mediálního menisku. (str. 40)

- Obrázek 25 T2 mapy, získané v artikulární chrupavce u 51 letého muže po reparaci vazů ukazuje vyšší T2 hodnoty (žlutá) v mediálním (a) a laterálním (b) tibio-femorálním kompartmentu, nálezy indikující zhoršení integrity a orientace kolagenní sítě. Mapy jsou získány MR 3T s sagitální 3D T2 váženou SE sekvencí. (str. 41)
- Obrázek 26 (a) Předoperační sagitální 2D obraz kolenní oblasti, získaný na základě protonové denzity s potlačením tuku 20leté ženy demonstruje značný osteochondrální defekt femorálního kondylu (šipky) s subchondrální cystickou formací (hrot šipky). (b) Pooperační sagitální 2D obraz kolenní oblasti, získaný na základě protonové denzity s potlačením tuku, získaný 18 měsíců po autologním chondrocytickém implantátu ukazuje heterogenní reparaci tkání (šipky) a jemný dřevňový edém (hrot šipky). (c) Sagitální T2 mapa, získaná na základě multiecho sekvence ve stejném čase jako (b) poukazuje na oblasti tkáňové reparace s heterogenní T2 signálovou denzitou (šipky). (str. 42)
- Obrázek 27 Komparace indexu dGEMRIC, získaného u pacienta s kolenní osteoartritidou (a) a získaný obraz u zdravého subjektu. (a) ukazuje nižší indexovací hodnoty v (b), nálezy, reprezentující vyprázdnění glykosaminoglykanového obsahu v artikulární chrupavce (hrot šipky) a degenerace mediálního menisku. Škála je generována v milisekundách. (str. 43)
- Obrázek 28 Komparace T1ρ map, získaných v kolenní chrupavce u zdravého subjektu (a) a pacienta s vážnou osteoartritidou (b) ukazuje vyšší hodnoty T1ρ v (b). Střední hodnoty v mediálním femorálním kondylu byly 32,9 msec ± 9,0 v (a) a 49,1 msec ± 14,2 v (b). (str. 44)
- Obrázek 29 Celkový sodíkový MR obraz získaný na základě protonové vážené denzity SPGR sekvence u 20 letého dobrovolníka ukazuje vyšší signálovou intenzitu v chrupavce v mediálním kompartmentu. Obraz byl pořízen 3.0 T s kvadrurní sodíkovou cívkou a 3D kužely, odečítající trajektorii s prostorovým rozlišením 1.25x1.25x4 mm a akvizičním časem 20 min. Stupnice je generována v mili molech. (str. 45)
- Obrázek 30 Sagitální ADC mapa, získaná na základě difuzně váženého MR zobrazování v kolenu u asymptotického 28letého muže ukazuje region vyšší signálové intenzity mediálního femorálního kondylu. Obraz byl pořízen 3.0 T (TR/TE=2200/73, b=600 sec/mm², tloušťka=5mm, mřížka=192x192). (str. 46)
- Obrázek 31 Komparace sagitálních 3D SPGR MR obrazů, získaných na 3.0T (a) a 7.0T (b) v oblasti kolena u zdravého dobrovolníka neukazují výrazné diference v manifestaci artikulární chrupavky, ačkoliv artefakty, způsobené magnetickou susceptibilitou jsou zhoršené v silnějším magnetickém poli ve tkáních, jako je trabekulární kost (hrot šipky v (b)). (str. 47)
- Obrázek 32 Nalezená hranice chrupavky, pomocí N generovaných paprsků od středního bodu a nález gradientu. (str. 51)

- Obrázek 33 2D mapa opotřeбенí artikulární chrupavky pacienta s osteoartritidou (vlevo) a normálního subjektu (vpravo). Arteficiální barevná mapa koresponduje s tloušťkou chrupavky od nejnižší hodnoty (černá) až po nejvyšší (zelená). (str. 51)
- Obrázek 34 Segmentace femorální chrupavky. (a) Bezier splines, generované z kontrolních bodů. (b) Liniový profil pro nalezení rozhraní mezi kostí a chrupavkou. (c) Liniové profily pro nalezení povrchu artikulární chrupavky. (d) Rozhraní mezi kostí a chrupavkou (tyrkysová barva) a povrch artikulární chrupavky (červeně anilinová barva) jako výsledek segmentace. (str. 53)
- Obrázek 35 Segmentace patelární chrupavky v jednom řezu se sub-pixelovou přesností. Fragment kontury ukazuje rozhraní mezi chrupavkou a kostí (nahore) a povrchem chrupavky (dole). Uzly v kontuře indikují hranové body, které byly určeny v rámci předzpracování obrazu. (str. 54)
- Obrázek 36 Syntetický MR obraz kolena na základě sloučení 100 obrazů. (a) Tibiální kost a chrupavka. (b) Femorální kost a chrupavka. (str. 57)
- Obrázek 37 (a) Klasifikace tkání na základě jasů a homogenity voxelů v sousedství. (b) Výsledná maska chrupavky překrytá do profilové mapy. (str. 58)
- Obrázek 38 Komparace zlatého standardu s automatickou segmentační metodou SVM-DRF. (str. 59)
- Obrázek 39 (a) Lokace prototypové masky po adaptivní translaci. (b) Koincidence zlatého standardu a segmentace. (str. 61)
- Obrázek 40 Automatické rozhraní extrakce kost-tkáň, následované segmentací chrupavky. (str. 62)
- Obrázek 41 Vývojový diagram segmentačního modelu kolena. (str. 63)
- Obrázek 42 Klinický MRI řez podél seed regionu, který je interaktivně získán (vlevo). Výsledek adaptivní metody region growing s využitím semínek (uprostřed). Výsledek metody snake-like regularizer, získaný metodou region growing (vpravo). (str. 63)
- Obrázek 43 Výstupy segmentace chrupavky na základě pravděpodobnostního segmentačního modelu. (str. 65)
- Obrázek 44 Komparace originálního záznamu (vlevo) a optimalizovaného záznamu (vpravo). (str. 65)
- Obrázek 45 Nativní MR obraz s odhadovaným femorálním centrem (b) a 3D pohled na femorální centrum na základě Houghovy transformace (c). (str. 66)
- Obrázek 46 Detekce hran femorální chrupavky a potlačení šumu. (str. 66)
- Obrázek 47 Blokový diagram segmentační metody, využívající rozpoznávání vzorů. (str. 67)

- Obrázek 48 Vývojový diagram detekce hran, založený na iterativním prahování. (str. 68)
- Obrázek 49 Příklad klasifikace šumové složky na základě pevného prahování. (str. 71)
- Obrázek 50 Originální obrazová data z MR 3T, PD sekvence kolenní oblasti s obrazovým rozlišením 512x512 pixelů. (str. 72)
- Obrázek 51 Fokusovaná oblast zájmu (RoI) nativních snímků kolenní chrupavky 74x183 pixelů. (str. 73)
- Obrázek 52 RoI s aplikovanou kubickou interpolací druhého řádu. (str. 73)
- Obrázek 53 RoI s aplikovanou kubickou interpolací třetího řádu. (str. 73)
- Obrázek 54 RoI s aplikovanou kubickou interpolací čtvrtého řádu. (str. 73)
- Obrázek 55 Komplexní struktura navrhované metodologie segmentace a modelování artikulární chrupavky. (str. 75)
- Obrázek 56 Posloupnost triangulárních fuzzy funkcí specifikující jednotlivé obrazové regiony. (str. 77)
- Obrázek 57 Evoluce aktivní kontury od inicializační elipsy až po finální konturu. (str. 80)
- Obrázek 58 Naivní data (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). (str. 81)
- Obrázek 59 Naivní data - RoI (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). (str. 81)
- Obrázek 60 Naivní data: rychlé spinové echo, T1 vážený obraz (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). (str. 82)
- Obrázek 61 Naivní data: 3D gradientní echo (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). (str. 82)
- Obrázek 62 Naivní data: rychlé spinové echo, proto-denzní obraz, bez potlačení tuku (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). (str. 82)
- Obrázek 63 Indikace manuální segmentace (vlevo) a binární model artikulární chrupavky (vpravo). (str. 83)
- Obrázek 64 Komparace automatické segmentace artikulární chrupavky na základě metody aktivních kontur (vlevo) a manuální segmentace (vpravo). (str. 83)
- Obrázek 65 Obecná struktura genetického algoritmu. (str. 89)

- Obrázek 66 Komplexní struktura ABC algoritmu pro optimalizaci soft prahovací metodologie. (str. 90)
- Obrázek 67 Optimalizace těžiště (V_k) segmentační třídy. (str. 92)
- Obrázek 68 Typický průběh fitness funkce pro 100 inicializačních řešení ABC algoritmu. (str. 95)
- Obrázek 69 (a) Nativní RoI obrazová MR data artikulární chrupavky obsahující počínající ztrátu chrupavky a (b) segmentační model fyziologické chrupavky na základě arteficiální barevné mapy, indikující příslušný stupeň členství. (str. 96)
- Obrázek 70 (a) Normalizovaný histogram RoI (Obr. 69) a (b) aproximace na základě 6 fuzzy množin. (str. 96)
- Obrázek 71 Posloupnost dílčích segmentačních modelů artikulární chrupavky na základě 6 segmentačních množin, reprezentovaných výstupy a) – f). (str. 97)
- Obrázek 72 Okolí 3x3 analyzovaného pixelu, který je indikován červeně. a) Nepředpokládá se prezenze šumové složky. b) Analyzovaný středový pixel, představující šumovou složku. (str. 101)
- Obrázek 73 Kalkulace hodnoty členské funkce na základě mediánu analyzovaného pixelu, který je indikován červeně. a) Nepředpokládá se prezenze šumové složky. b) Analyzovaný středový pixel, představující šumovou složku. (str. 102)
- Obrázek 74 Komparace segmentačních výstupů na RoI 250x200 pixelů s analyzovaným počtem segmentačních množin: 3 (a), 5 (b), 7 (c) a 10 (d). (str. 106)
- Obrázek 75 Komparace segmentačních výstupů na RoI 500x400 pixelů s analyzovaným počtem segmentačních množin: 3 (a), 5 (b), 7 (c) a 10 (d). (str. 106)
- Obrázek 76 RoI se superponovaným šumem Salt and Pepper s variantní šumovou hustotou (d): (a) $d=0.05$, (b) $d=0.1$, $d=0.5$ a (d) $d=0.8$. (str. 107)
- Obrázek 77 Výstup segmentace se superponovaným šumem Salt and Pepper s variantní šumovou hustotou (d): (a) $d=0.05$, (b) $d=0.1$, $d=0.5$ a (d) $d=0.8$. (str. 107)
- Obrázek 78 RoI se superponovaným Gaussovským šumem se střední hodnotou (μ) a variancí (σ): (a) $\mu=0$, $\sigma=0.01$, (b) $\mu=0$, $\sigma=0.08$, (c) $\mu=0$, $\sigma=0.1$ a (d) $\mu=0$, $\sigma=0.8$. (str. 108)
- Obrázek 79 Výstup segmentace se superponovaným Gaussovským šumem se střední hodnotou (μ) a variancí (σ): (a) $\mu=0$, $\sigma=0.01$, (b) $\mu=0$, $\sigma=0.08$, (c) $\mu=0$, $\sigma=0.1$ a (d) $\mu=0$, $\sigma=0.8$. (str. 108)
- Obrázek 80 RoI se superponovaným multiplikativním šumem se střední hodnotou (μ) a variancí (v): (a) $\mu=0$, $v=0.01$, (b) $\mu=0$, $\sigma=0.08$, (c) $\mu=0$, $\sigma=0.1$ a (d) $\mu=0$, $\sigma=0.8$. (str. 108)

- Obrázek 81 Výstup segmentace se superponovaným multiplikativním šumem se střední hodnotou (μ) a variancí (v): (a) $\mu=0$, $v=0.01$, (b) $\mu=0$, $\sigma=0.08$, (c) $\mu=0$, $\sigma=0.1$ a (d) $\mu=0$, $\sigma=0.8$. (str. 109)
- Obrázek 82 Výsledek komparativní analýzy mediánové agregační procedury. Testovací RoI 500x400 pixelů (a), mediánový agregát s maskou: 3x3 (b), 7x7 (c), 15x15 (d) a 23x23 (e). (str. 110)
- Obrázek 83 Výstup mediánové agregační procedury s velikostí okna 23x23, kde ztenčení kontury chrupavky je indikováno červeným RoI. (str. 110)
- Obrázek 84 Nativní obrazová data z PD sekvence s vyznačeným RoI, kde je předpoklad porušení celistvosti artikulární chrupavky (a), RoI bez interpolace (b) a RoI s kubickou interpolací (c). (str. 112)
- Obrázek 85 Výstup segmentační procedury soft prahování (6 klasifikačních tříd) bez využití interpolační techniky. (str. 113)
- Obrázek 86 Výstup segmentační procedury soft prahování (6 klasifikačních tříd) s využitím adaptivní interpolační techniky ($F=8$). (str. 113)
- Obrázek 87 Nativní MR obrazová data s vyznačeným RoI (vlevo), segmentační výstup (4 klasifikační třídy) (uprostřed) a finální model kolenní chrupavky, reflektující chondromalacii I. Stupně, která je obtížně pozorovatelná z nativních záznamů (vpravo). (str. 114)
- Obrázek 88 Nativní MR obrazová data s vyznačeným RoI (vlevo), segmentační výstup (4 klasifikační třídy) (uprostřed) a finální model kolenní chrupavky, reflektující chondromalacii I. Stupně, která je obtížně pozorovatelná z nativních záznamů (vpravo). (str. 114)
- Obrázek 89 Časově inverzní kolenní obraz indikující plně chondrální defekt (šipky) s vyznačeným RoI pro segmentaci (červeně). (str. 115)
- Obrázek 90 Segmentační model (8 klasifikačních tříd) časově inverzního kolenního obrazu po extrakci regionu kolenní chrupavky doplněnou morfologickou erozí, kde chondrální defekt je ostře ohraničen (žlutá kontura) v červeném RoI. (str. 115)
- Obrázek 91 Nativní data kolenní oblasti, získané na základě 2D SE zobrazování. Nativní obraz poskytuje lepší kontrast mezi povrchem chrupavky, synoviální tekutinou. Vysoký kontrast dobře diferencuje chrupavčitý defekt (hrot šipek), kde modré RoI indikuje oblast zájmu pro segmentaci. Segmentační výstup (8 segmentačních množin) lokalizuje oblast části kolenní chrupavky, chrupavčitý defekt je ostře ohraničen žlutou konturou v červeném RoI (b). (str. 115)

- Obrázek 92 T2 vážený obraz s potlačením tuku reflektuje lokace kompletní ztráty chrupavky v mediální tibiofemorální oblasti s degenerativními lézemi v subchondrální kosti (hrot šipky), kde červené RoI indikuje oblast zájmu pro segmentační proceduru (a). Výstup segmentačního modelu kolenní chrupavky reflektující největší signálovou intenzitu (žluté kontury), naopak model detekuje lokace, kde dochází ke ztrátě chrupavky (červené oblasti zájmu), degenerativní léze jsou ostře ohraničeny žlutou konturou v modrém RoI (b). (str. 116)
- Obrázek 93 Sagitální 3.0T MR obraz kolenní oblasti zdravého dobrovolníka, nevykazující signifikantní diference v oblasti manifestace kolenní chrupavky (a), segmentační model kolenní chrupavky, identifikující celistvost morfologické struktury (žlutá kontura), model je generován po aplikaci morfologické eroze, eliminující drobnější shluky pixelů (b). (str. 117)
- Obrázek 94 Sagitální 7.0T MR obraz kolenní oblasti zdravého dobrovolníka, nevykazující signifikantní diference v oblasti manifestace kolenní chrupavky, nativní data rovněž vykazují artefakty, způsobené magnetickou susceptibilitou, což je indikováno hrotem šipky (a), segmentační model kolenní chrupavky, identifikující celistvost morfologické struktury (žlutá kontura), model je generován po aplikaci morfologické eroze, eliminující drobnější shluky pixelů (b). (str. 117)

Seznam tabulek

- Tabulka 1 Validace metody aktivních kontur pro nativní MR data. (str. 84)
- Tabulka 2 Parametry třídících intervalů distribuce jasového spektra artikulární chrupavky. (str. 87)
- Tabulka 3 Komparace intervalových odhadů jasové distribuce artikulární chrupavky. (str. 88)
- Tabulka 4 Komparace výsledků ABC optimalizace. (str. 94)
- Tabulka 5 Výpočetní náročnost ABC optimalizace. (str. 94)
- Tabulka 6 Komparativní analýza metody soft prahování s vybranými metodami (str. 106).

Úvod

Zásadní význam na pohybový aparát má stav a kondice kloubní chrupavky. Kondice chrupavky je jedním z nejdůležitějších faktorů, které ovlivňují kvalitu života v pozdním věku. Značnou dispoziční k opotřebenosti má kloubní chrupavka velkých nosných kloubů, zejména se jedná o kolenní klouby. Kolenní chrupavka bývá často postižena patologickými procesy, narušujícími její celistvost. Důležitým faktem je včasná detekce a lokalizace patologických procesů chrupavky, které často vedou k nevratnému poškození, nebo k celkové ztrátě chrupavky. Z klinického hlediska je důležité hodnocení chondromalacie a ztráty chrupavky, které vedou k porušení morfologické struktury kolenní chrupavky. [1]

Z hlediska vyšetření kolenní chrupavky je standardně klinicky využíváno zobrazovacích metod (MR, UZV, RTG). Z klinického hlediska je důležité, aby příslušná zobrazovací metoda umožňovala rozlišení morfologických struktur tak, aby bylo možné identifikovat patologické procesy v raném stádiu, které často vedou k následnému vážnému poškození chrupavky, značně omezující hybnost jedince. Klinicky nejfrekventovanější zobrazovací modalitou pro kolenní chrupavky je MR (magnetická rezonance). MR, v porovnání s ostatními metodami, poskytuje nejoptimálnější kontrast a vysoké rozlišení. Stěžejním benefitem MR zobrazování je široká nabídka sekvencí, umožňujících selekci určitých kolenních struktur, zatímco signál chrupavky je maximálně zesílen, což vede ke kontrastnímu zobrazení. [1]

Disertační práce se věnuje modelování kolenní chrupavky s primárním cílem extrakce počínajících degenerativních změn v raném stádiu. Ztráta chrupavky je klinicky klasifikovatelná ve čtyřech stádiích v závislosti na progresi onemocnění. Z hlediska hodnocení MR obrazů je nejzajímavější I. stupeň. V této prvotní fázi patologického procesu dochází k prvotnímu porušení morfologické struktury kolenní chrupavky. Stěžejním problémem prvotní fáze je obtížná obrazová manifestace místa, kde dochází k těmto změnám, tudíž je komplikované spolehlivě určit diagnózu z nativních MR obrazových dat.

Hlavní oblastí zájmu disertační práce je návrh multiregionálního segmentačního modelu, který umožňuje separaci jednotlivých struktur kolenní chrupavky. Tento přístup umožňuje selekci a extrakci chrupavky, zatímco okolní struktury jsou eliminovány. Důležitou vlastností segmentačního modelu je vysoká senzitivita, umožňující identifikovat a klasifikovat fyziologickou část chrupavky, a patologická místa, která indikují oblast, kde chrupavka chybí.

Častým problémem segmentačních metod je ostrá klasifikace pixelů do klasifikačních tříd. Tato vlastnost se negativně projevuje zejména v případech, kdy obrazová data jsou ovlivněna šumovou složkou, která je v určité míře běžnou součástí medicínských obrazových dat. V obecné rovině u jasově orientované segmentace platí, že pixely náležící do stejného jasového spektra, jsou klasifikovány do stejné segmentační třídy. Předpokládá se, že šumová složka, znehodnocující obrazovou informaci, je reprezentována signifikantně odlišnou jasovou úrovní, než jasová funkce objektu, který je v popředí našeho zájmu. Tímto způsobem je šum, ležící uvnitř segmentovaného předmětu, klasifikován do variabilní třídy než samotný objekt, což vede k nekorektnímu výstupu segmentační procedury, neboť v segmentačním modelu vznikají prázdná místa (blind spots) a model objektu není konzistentní. Tento fenomén může teoreticky být kompenzován na základě doplňkových procedur, zahrnujících např. morfologické operace, nicméně takové operace modifikují originální

strukturu obrazu a hlavně kvalitu a reprodukovatelnost klinických informací. Alternativou, která je efektivněji využitelná v oblasti zpracování medicínských obrazových dat, je multiregionální segmentační model, využívající tzv. soft klasifikaci pixelů na základě fuzzy funkcí členství namísto klasifikace s pevně stanovenou hranicí. Předpokladem takového přístupu je fakt, že každý pixel je popsán v multiregionálním modelu pomocí vektoru hodnot členských funkcí namísto jasových hodnot. Lze tedy v jistém slova smyslu mluvit o fuzzy deskriptoru pixelů. Důležitým aspektem segmentační procedury segmentačního modelu je lokální agregační procedura. Tato procedura zajišťuje vyšší robustnost metody vůči šumu. Hlavním účelem agregace je využívání tzv. lokální prostorové informace z okolí pixelů. Agregace zkoumá okolí pixelů pomocí statistických operátorů, které mohou měnit charakter hodnot členských funkcí. Tato vlastnost segmentační procedury umožňuje modifikovat hodnotu členské funkce příslušného pixelu, a tudíž klasifikaci pixelu do jiné třídy v rámci segmentačního modelu na základě analýzy prostorových relací každého pixelu.

V rámci modelování kolenní chrupavky na základě multiregionálního modelu je řešena analýza obrazových dat z MR sekvencí. Počínající patologické změny jsou zejména hodnoceny z PD (proton-denzní) sekvence a sekvence využívající potlačení tuku. Z hlediska spolehlivosti modelu je důležitá reflexe na místa, kde nedochází k morfologickému přerušení chrupavky vůči lokacím, kde je celistvost chrupavky narušena, či chrupavka úplně chybí. Důležitým aspektem modelu je rovněž analýza jeho robustnosti při postupném navyšování šumové složky.

Efektivita a přesnost segmentační procedury může být hodnocena na základě zlatého standardu, který je zejména určen manuální segmentací. Za tímto účelem je jako protiváha vůči multiregionálnímu modelu stavěna segmentace, využívající metody aktivních kontur, která je verifikována expertní manuální segmentací. Výsledek navrhovaného modelu je následně komparován vůči zlatému standardu.

1 Artikulární chrupavka

Artikulární chrupavka představuje specializovaný typ vazivové tkáně, která vzniká z mezenchymu. Chrupavka je tvořena buněčnou matrix a chondrocyty. Hlavní funkcí chrupavky je podpora měkkých tkání. Chrupavka disponuje pružností a hladkým povrchem, což umožňuje kostem v kloubech klouzavý pohyb. Chrupavka je esenciální částí vývoje a růstu dlouhých kostí před a po narození. [1]

Chrupavky jsou kryty hutnou vazivovou tkání, která je bohatá na kolagen, perichondrium. Vazivová tkáň obsahuje četné fibroblasty a také cévní řečiště, které zajišťuje výživu chrupavky. Kloubní chrupavka je vyživována cestou synoviální výstelky kloubu. Chrupavka neobsahuje lymfatické cévy, taktéž není inervována. [1]

Evoluce chrupavky je ovlivněna somatotropním hormonem, který zajišťuje syntézu somatomedinu v játrech. Somatomedin přímo ovlivňuje buňky chrupavky a podmiňuje jejich růst. Dle histologické struktury se chrupavka dělí na tři základní typy: elastickou, vazivovou a hyalinní. [1, 3]


1.1 Hyalinní chrupavka

Kontaktní plochy kloubů jsou potaženy tzv. hyalinní chrupavkou. Čerstvá je modrá až bílá a bývá transparentní. Je tvořena z cca 1% chondrocyty a kolagenními vlákny. Tato vlákna zajišťují vysokou pevnost a tuhost v tahu. Kolagenní vlákna probíhají chrupavkou ve třech vrstvách. Hluboká vrstva navazuje na subchondrální kost. Toto uspořádání vláken do vrstev má největší význam především při zátěži. [2]

Tloušťka kloubní chrupavky je úměrná velikosti tlaku, který působí na jednotku její plochy a rozsah pohybů v kloubu. Z tohoto důvodu tloušťka chrupavky není rovnoměrná. Silnější bývá v centru kloubních ploch, naopak slabší je v periferiích. [2, 3]

1.2 Morfologie kloubní chrupavky

Z hlediska morfologie lze chrupavku dělit na 4 základní zóny: povrchová, přechodná, radiální hluboká a zóna kalcifikované chrupavky. Jednotlivé chrupavčité zóny nejsou pevně ohraničeny a vzájemně se prolínají. Buňky v jednotlivých zónách se liší tvarem, ale také velikostí a orientací k povrchu a také metabolickou aktivitou. Schopnost chrupavky odolávat kompresním silám a zátěži při dopadu se obzvláště podílí přechodná a radiální chrupavčitá zóna. [2, 3]



Obrázek 1 Struktura hyalinní chrupavky. [3]

Povrch této zóny tvoří ochranný film, který je tvořen jemnými fibrilami polysacharidů, které mají za úkol eliminovat kontakt chondritů s kloubním povrchem. Pod touto vrstvou se nacházejí tvarově ploché a elipsoidní chondrocyty, které svou delší osu směřují paralelně s kloubním povrchem. Chondrocyty produkují látku, která je bohatá na kolagen, kolagenní fibrily jsou orientovány paralelně s kloubním povrchem. Tímto faktem se zvětšuje odolnost a pevnost chrupavky vůči tahu. [2, 3]

a) Přechodová zóna

Chondrocyty v této zóně mají sférický tvar, produkují velké množství proteoglykanových agregátů. Kolagenní fibrily jsou větších rozměrů a jsou orientovány tangenciálně k povrchu. [3]

b) Radiální hluboká zóna

Kolagenní fibrily jsou orientovány radiálně ke kloubnímu povrchu. Buňky jsou sférického tvaru. V této vrstvě je typická vysoká koncentrace proteoglykanů, agrekanu a nízký obsah dekorinu, biglykanu a vody. [3]

c) Zóna kalcifikované chrupavky

Tato zóna navazuje na subchondrální kost, je částečně kalcifikována. Chondrocyty jsou méně objemné a z metabolického hlediska mají extrémně nízký obrat. [3]

d) Kost

1.3 Cévní zásobení kloubní chrupavky


Chrupavka neobsahuje vlastní cévní zásobení, ani nervová vlákna. Výživa chrupavky probíhá jednak difuzí ze synoviální tekutiny a také z subchondrálních cév. Chrupavka se vyznačuje nízkou koncentrací kyslíku. Glukóza potřebná pro metabolismus je vedena cestou anaerobní glykolýzy. Pomalý metabolismus způsobuje zpomalení reparačních procesů v chrupavce. Z tohoto důvodu každé poškození chrupavky se hojí i několik měsíců. I přes nízký metabolický obrat v chrupavce dochází ke kontinuální náhradě a rovněž výměně buněk. [2, 3]

1.4 Vlastnosti kloubní chrupavky

Biologické stáří kloubu je dáno stavem kloubní chrupavky. Struktura chrupavky je schopná dlouhodobě odolávat tlakům až do čtyřnásobné tělesné hmotnosti. Tyto pevnostní vlastnosti jsou podmíněny obsahem proteoglykanů a specifickým uspořádáním kloubních fibril. Odolnost chrupavky se v průběhu života snižuje zejména na podkladě nedostatečných reparačních procesů. [4]


1.5 Femoropatelní skloubení

Femoropatelní kloub tvoří součást složeného kloubu kolenního. V tomto místě se střetávají femur, tibia a patela. Mezi styčné plochy femuru a tibie jsou vloženy kloubní menisky. [4]



Obrázek 2 Anatomie kolenního kloubu. [4]


Patela je považována za sezamskou kost v úponové šlaše čtyřhlavého svalu stehenního. Kloubní plocha přilehlá k prohnuté fascies patellaris femuru, mezi kondyly, je podélně zlomena na dvě facety. [4]




Obrázek 3 Anatomie pately. [4]

1.5.1.1 Tvar pately

Šířka a výška pately jsou konstantní, ovšem tloušťka je značně variabilní. Např. ve střední rovině se pohybuje v rozmezí 2 až 3 cm. Kloubní plocha pately je rozdělena vertikální hranou na laterální, která je standardně větší a konkávní, a mediální, která je obvykle menší a konvexní. Vzájemným tvarem a velikostí faset se zabývali Wiberg a Baumgartl. Dle zmiňovaných autorů rozeznáváme šest základních tvarů česky. [1, 5]



Obrázek 4 Wibergova-Baumgartlova klasifikace tvaru pately. [6]



Obrázek 5 Tvarové anomálie češky. [6]

Mediální kloubní plocha vykazuje největší anatomické změny. Tato část je rozdělena na mediální fasetu a mnohem menší tzv. odd fasetu podél střední hranice pately. Tyto fasety jsou odděleny menším vedlejším hřebenem. Vyvíjí se od porodu v reakci na funkční zatížení působící na kolena. Sekundární hřeben probíhá šikmo na podélnou osu pately spíše proximálněji, než distálněji. [18, 19]

Laterální kloubní plocha je konkávního tvaru v horizontálním i vertikálním směru, je rozdělena na tři hlavní segmenty, které jsou odděleny dvěma vyvýšeninami dle funkčního významu sledující flekční pohyb ve femoropatelním kloubu. [20]

Počet a tvar kloubních facet pately je u každého jedince unikátní. Kloubní chrupavka pately dosahuje v oblasti crista patellae tloušťky 4-7 mm, což představuje v kloubech lidského těla maximum. Směrem k okraji se postupně snižuje, výjimku tvoří pouze paramediální hrana, kde je chrupavka oproti okolí silnější. [1, 7, 17]

1.5.2 Postižení femoropatelního kloubu

Postižení lze klasifikovat do dvou základních skupin, a to traumatická a netraumatická. Mezi nejvýznamnější skupinu kloubních onemocnění patří osteoartróza a chondropatie. [17]

Na základě klinického obrazu pacienti s patelní symptomatologií pociťují bolestivost přední části kolena, případně nestabilitu. Pociťují bolest zejména při vstávání ze sedu, při chůzi po schodech a také při dřepnutí, kdy v kloubu působí enormní tlakové síly. Femoropatelní dysfunkce může být definována jako bolest, dysbalance, zánět, nebo instabilita jakékoliv komponenty extenčního mechanismu kolena. [8, 9, 10]

1.5.2.1 Chondromalacie

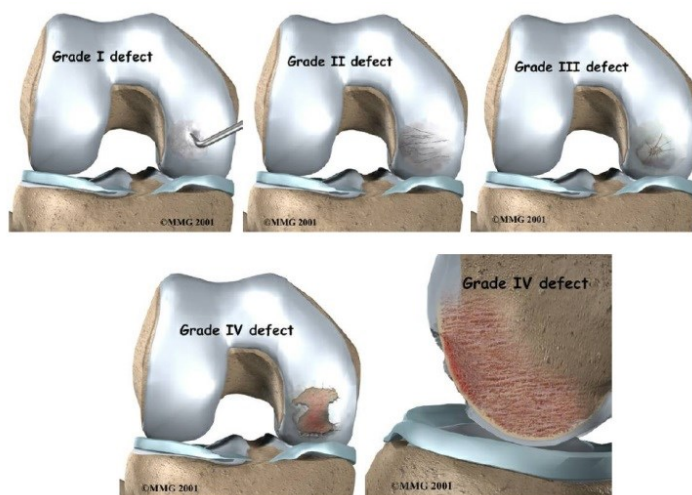
Chondromalacie, neboli chondropatie je patologický stav, při němž dochází ke změknutí chrupavky, často také k rozvlákněním, fisuracím a erozím. Podle rozsahu makroskopického postižení, chondromalacie je klasifikována do 4 stupňů (Obr. 6). [11, 12, 16]

I. stupeň: Ložisko je menší než 5mm v průměru, dochází k edematóznímu zduření a měknutí konzistence chrupavky. Povrch chrupavky je obvykle matný a nažloutlý.

II. stupeň: Fibrilace chrupavky v rozsahu do 15 mm.

III. stupeň: Fibrilace až fascikulace povrchu chrupavky nad 15 mm, fascikulace značí poškození chrupavky v celé šíři. Jedná se již o symptomatické postižení na základě biochemického podkladu. Modifikovaná chrupavka přenáší většinu tlakové zátěže na subchondrální kost. V tomto místě dochází k dráždění nervových zakončení.

IV. stupeň: Obnažení subchondrální kosti. Tento jev se může vyskytnout v každém věku. Častěji bývají postiženi dospělí. Z genderového pohledu bývají častěji poškozeny ženy oproti mužům, a to v poměru 3:2. Většinou není přítomen kloubní otok, ani omezení hybnosti. [13, 14, 15, 21]



Obrázek 6 Klasifikace jednotlivých stádií chondromalacie. [6]

2 Vyšetřovací metody artikulárních chrupavek


2.1 Nativní snímky

Mezi radiodiagnostickými metodami zaujímá majoritní postavení klasické rentgenové vyšetření, které umožňuje získat širokou škálu informací o stavu a kondici kloubu obecně a tímto doplnit klinické výsledky (Obr. 7). Značnou výhodou této metody je morfologické zobrazení, které umožňuje potvrzení patologických změn, určení jejich rozsahu a také lokalizaci. Jedná se o frekventovaně využívanou metodu pro zobrazování artikulárních chrupavek. Na druhou stranu je tato metoda pro hodnocení stavu a kondice kloubní chrupavky značně subjektivní, a tedy i dosti nepřesná. [22, 23, 24, 25, 29]



Obrázek 7 Rentgenový snímek artikulární chrupavky: předozadí (a), boční pohled levého kolena (b), axiální snímek pately (c). [23]


Existují jisté teoretické pokusy, které mají vést k metodě hodnocení šíře kloubní štěrbiny, a tedy nepřímě ke stavu artikulární chrupavky (Obr. 8). Zejména je zde kladen důraz na přesnou snímkovací techniku, kde paprsek směřuje kolmo na kloubní štěrbinu. Avšak v praxi tyto techniky nejsou konvenčně používány. [26, 27, 28]



Obrázek 8 Vymezení femorálního a tibiálního rozpětí, které umožňuje výpočet střední šíře kloubní štěrbiny při normalizované vzdálenosti mediálního a laterálního kompartmentu, což je indikováno růžovou linií. Minimální šíře kloubní štěrbiny je indikována žlutou linií ve vertikálním směru. [23]

2.2 Ultrasonografie

Parciální roli v oblasti zobrazování artikulárních chrupavek zaujímá ultrasonografie. Značnou nevýhodou této zobrazovací modalidy je znemožnění přehlednosti okolních struktur. Z tohoto pohledu plyne, že tato metoda je klinicky neposouditelná. Ultrasonografie hraje důležitou úlohu v diagnostice preartrotických stavů, především v oblasti ramenního a kolenního kloubu a při detekci výpotků. [30, 31, 32, 33, 34, 35]



Obrázek 9 Nepoškozená chrupavka v UZV obraze. Zdroj: vlastní




Obrázek 10 Chrupavka v UZV obraze, část chondromalacie je indikována šipkou. Zdroj: vlastní

2.3 Magnetická rezonance (MR)

Dominantní postavení mezi vyšetřovacími metodami v oblasti kloubních patologií zaujímá magnetická rezonance (MR). V současné době je vyšetření kloubů na základě magnetické rezonance nejcitlivější zobrazovací metodou. Sekvence magnetické rezonance umožňují optimalizaci zobrazení morfologie artikulární chrupavky, volumetrická vyšetření a také metody biochemické analýzy. [36, 37]

Magnetická rezonance disponuje vysokou rozlišovací schopností, zejména prostorovým rozlišením. Díky této schopnosti je ideální metodou k zobrazení měkkých tkání kloubu a chrupavky v celé šíři včetně přítomných patologií. Značným benefitem je neinvazivnost v důsledku zatěžování pacienta. Další výhodou moderních MR přístrojů je využití sekvencí, které umožňují optimalizaci rozlišení chrupavčité tkáně. V současnosti jsou nejběžněji používané sekvence protonové denzity (PD), která udává hustotu protonů na jednotku objemu, a MR sekvence s potlačením tuku. [38, 39]


Současné MR zobrazovací techniky umožňují zkoumání morfologické struktury chrupavky. Tyto metody se člení na konvenční spin-echo sekvence (SE), gradientní recall echo sekvence (GRE), rychlé SE sekvence a pokročilejší isotropní 3D SE a GRE sekvence. Kompoziční techniky zahrnují T2 mapování, zobrazovací techniku artikulární chrupavky na základě zpoždování gadolinia (dGEMRIC), T1ρ zobrazování, zobrazování sodíku a vážené difuzní zobrazování. Následující textová část obsahuje recentní rešerši současně dostupných MR zobrazovacích technik pro vyhodnocení morfologických a kompozitních charakteristik artikulárních chrupavek. Jsou rovněž diskutovány specifické aplikace pro každou z technik v oblasti detekce a posouzení chrupavčitého poškození, nebo chorob, jako je osteoartritida. [40, 41]



Obrázek 11 Zobrazování artikulární chrupavky MR. Celistvost chrupavky je narušena počínající ztrátou chrupavky I. stupně. Tento fenomén je lokalizován červenou oblastí zájmu. Zdroj: vlastní

2.3.1 Morfologické hodnocení

MR zobrazovací techniky pro morfologické posouzení chrupavky poskytují přesné informace o procesech, jako jsou fisurace a fokální, nebo difuzní částečná, nebo plná ztráta tloušťky chrupavky. Morfologické MR zobrazování reparace chrupavek poskytují přesné pooperační informace o specifických parametrech, které jsou vybírány podle konkrétní operativní techniky, která je využita. V oblasti klinického výzkumu, obzvláště v případě kolenní osteoartritidy, morfologické hodnocení chrupavek s využitím MR technik je provedeno s využitím semikvantitativních skórovacích metod, jako jsou: WORMS (Whole-Organ MR Imaging Score), BLOKS (Boston-Leeds Osteoarthritis Scoring System) a KOSS (Knee Osteoarthritis Scoring System). U takových skóre systémů jsou posuzovány morfologické parametry artikulárních chrupavek ve spojení s okolními kolenními strukturami, jako jsou např. menisky, subchondrální kost a synoviální kost, aby bylo možné založit morfologické risk faktory pro bolest a progresi onemocnění u pacientů, kteří trpí osteoartridou. Každá z technik disponuje svými klady a také slabinami pro různé klinické aplikace. [42-47]



Obrázek 12(a) Sagitální střední vážený SE obraz s potlačením tuku (TR msec/echo čas [TE] msec=4000/35). Jsou zobrazeny regiony s vysokou signálovou intenzitou kvůli chabému potlačení tuku (hrot šipky). **(b)** Sagitální střední vážený “IDEAL fast water image (TR/TE=4000/35)“ ukazuje cystu, která je indikována šipkou. Tato technika umožňuje lepší diferenciaci tuku a vody. [54]

2.3.2 MR techniky s potlačením tuku


Různé MR parametry zobrazování zahrnující tkáňové relaxační časy ovlivňují kontrast mezi tekutinou a chrupavkou. Technika potlačení tuku může být využita pro zvýšení kontrastu mezi lipidními a nelipidními povrchy, přidává dynamický rozsah a redukuje chemické artefaktové posuvy. V oblasti zobrazování artikulárních chrupavek techniky s potlačením tuku poskytují zvýšený kontrast subchondrální kosti od povrchu artikulární chrupavky. [48-50]

Většina běžně využívaných technik, založených na potlačení tuku, zahrnují excitaci a defázování spinových protonů v tuku na základě lipid – specifického radiofrekvenčního pulzu, aplikovaného před každou repeticí 2D, nebo 3D SE, nebo GRE zobrazovací sekvence. Jedna z nevýhod pro využití techniky s potlačením tuku v kombinaci s 3D GRE sekvencí, které jsou běžně využívány pro morfologické posouzení artikulárních chrupavek, je výrazné prodloužení akvizičního času. Navíc, tato chemicky selektivní technika potlačení tuku je náchylná k nehomogenitám magnetického pole generovaných magnetickými diferencemi kvůli lokálním faktorům, jako jsou presence kovových předmětů. Tento fakt představuje běžný problém MR zobrazování kolenní oblasti. [50-53]



Obrázek 13 Časově inverzní obnovený obraz z oblasti kolena, přesně ukazující fokální plně chondrální defekt (šipky) na trochleární drážce. [54]

Iterativní dekompozice vody a tuku s asymetrickým echem a nejmenším čtvercovým odhadem (IDEAL) může poskytnout uniformní potlačení tuku v prostředí magnetického pole kolenní oblasti. Tato tří bodová "water-fat" separační technika spoléhá na využitelnost asymetrických ech a maximalizaci SNR na základě aproximační metody nejmenších čtverců. Může být také použita ve spojení buď se SE, nebo GRE technikou. [54]




Obrázek 14 Sagitální 2D fast SE obraz, získaný na základě různých technik ze stejné kolenní oblasti. (a) T1 – vážený obraz ukazuje slabý kontrast mezi povrchem chrupavky a synoviální tekutinou, značnou nevýhodou je neposkytnutí informace pro přesné posouzení fokálního chrupavčitého defektu (hrot šipky). (b, c) T2 – váhování (b) a vážená protonová denzita. (c) Obraz poskytuje lepší kontrast mezi povrchem chrupavky synoviální tekutinou, umožňující identifikaci plného chrupavčitého defektu (hrot šipky) v mediálním femorálním kondylu. [54]

Další alternativní možností je spektrální excitační technika, kde spiny vody na povrchu jsou excitovány. Zobrazování na základě krátkého inverzního času je další možností pro posouzení oblastí, které mohou být ovlivněny nehomogenitami magnetického pole. Tato technika poskytuje metodu potlačení tuku, umožňující přesnou reprezentaci chrupavčitých defektů v kolenním kloubu. [54]


Zobrazování na základě excitace vody je založeno na selektivní excitaci protonů, které nejsou tukově vázané. Krátký TR přibližně 18 msec a malý flip úhel (15° - 40°) jsou běžně využívány pro reprezentaci chrupavky s velkou signálovou intenzitou a vysokým kontrastem pro okolní tkáň. Využití excitace vody poskytuje hlavní výhody z hlediska redukce akvizičního času a zmírněním artefaktů, které jsou způsobeny chemickými posuny. Excitace vody rovněž může být aplikována pro kvantitativní posouzení tloušťky chrupavky a jejího objemu. [55-58]

2.3.3 2D SE a rychlé SE zobrazování

MR zobrazovací sekvence jsou většinou používány ve 2D rovině nebo pro tzv. „multisection T1 weighted“, váženou protonovou denzitu a T2 vážené zobrazovací sekvence s, nebo bez potlačení tuku. T1 vážené obrazy ukazují anatomické detaily hyalinní chrupavky, ale neposkytují dostatečný kontrast mezi kloubním výpotkem a chrupavčítým povrchem, což je nedostatek, který limituje její využitelnost pro klinické posouzení lokálních chrupavčitých defektů. Navíc T1 váhování má chabou schopnost reprezentace ostatních interních struktur v kolenní oblasti jako jsou vazy. Také tato metoda může vést k nadsazení abnormalit menisků. T2 vážené zobrazování poskytuje dostatečný kontrast mezi chrupavčítým povrchem a kloubním výpotkem, který je užitečný pro detekci fokálních oblastí delaminace, nebo ostatních defektů. Nicméně toto představuje daň interního signálu chrupavky, který je zeslaben, protože některé z komponent chrupavky disponují krátkým T2. [56]



Obrázek 15 Axiální 2D T2 vážený rychlý SE obraz, poskytující excelentní reprezentaci fokálních regionů hluboké chrupavčité delaminace (šipky) s vysokým kontrastem mezi chrupavčítým povrchem a synoviální tekutinou. [54]




Obrázek 16 Axiální 2D T2 vážený rychlý SE obraz s nepotlačením tuku, poskytující excelentní kontrast mezi povrchem chrupavky a synoviální tekutinou, ale chrupavka je nedostatečně reprezentována s nízkou difuzní signálovou intenzitou. Současně je absence kontrastu mezi chrupavkou a kortikální kostí (vlevo).

Axiální 2D střední vážený rychlý SE obraz s potlačením tuku poskytuje excelentní kontrast mezi povrchem chrupavky, synoviální tekutinou a subchondrální kostí, také variaci intenzity signálu v průběhu chrupavky (vpravo). [54]

Ačkoli proton denzitní vážené zobrazování je schopné reprezentace povrchu defektů chrupavky, stejně jako abnormalit interní kompozice chrupavky, v některých případech je preferováno využívání středních vážených sekvencí, které kombinují výhodu kontrastu vážené protonové denzity. Tyto sekvence poskytují vyšší celkovou intenzitu signálu v chrupavce než standardní T2 vážené sekvence. Umožňují lepší diferenciaci mezi chrupavkou a subchondrální kostí. Kromě toho tyto sekvence jsou méně citlivé k efektu tzv. magického úhlu, který je viditelný u zobrazování na základě vážené protonové denzity s kratším TE. [57, 58]

2D rychlé nebo turbo SE zobrazovací sekvence poskytují excelentní SNR a kontrast mezi tkáněmi a konturami lézí u kolenní chrupavky. Protože echo jsou získána s repeticí každé sekvence, akviziční čas je kratší než u standardních SE sekvencí. 2D rychlé SE zobrazování je často využívanou technikou v klinické praxi pro posouzení abnormalit kolenního kloubu zahrnující léze chrupavek. [59]

Protonové denzitní vážené a T2 vážené rychlé SE zobrazovací techniky jsou optimálně navrženy pro morfologické posouzení artikulární chrupavky, stejně tak u menisků, vazových struktur, poskytující informace v porovnatelné kvalitě jako je tomu u operace. [59-63]



Obrázek 17(a) Koronární 3D střední vážený rychlý SE zdrojový obraz získaný s izotropním prostorovým rozlišením, neukazují se abnormality chrupavky. (b, c) Axiální (b) a sagitální (c) obraz získaný přeformátováním koronárního zdrojového obrazu. Manifestace chondrálního defektu (šipka) a trochleární drážky. [54]

Rychlé SE zobrazování představuje část protokolu, doporučeného asociací International Cartilage Repair Society. Ačkoliv rychlé SE sekvence poskytují excelentní SNR a kontrast mezi zájmovými tkáněmi, 2D rychlé SE zobrazování může být náchylné na anizotropní voxely, sekce, mezery a parciální objemové efekty. Navíc tato technika vyžaduje akvizici obrazu v tzv. multi plánech. [63]


2.3.4 3D rychlé SE zobrazování

3D GRE sekvence, které poskytují vysoké prostorové rozlišení obsahující izotropní voxely, jsou aplikovány pro zvýšení přesnosti MR zobrazování artikulární chrupavky, ale nejsou ideální pro posouzení přilehlé subchondrální kosti. Klinické hodnocení subchondrální kosti je klíčové v kontextu určení traumatických a degenerativních lézí artikulární chrupavky. V současnosti 3D střední vážené rychlé SE sekvence jsou aplikovány pro získání obrazů kolenního kloubu s vysokým kontrastem a izotropním prostorovým rozlišením. Rychlé SE pulzní sekvence a ostatní MR zobrazovací techniky, které poskytují izotropní prostorové rozlišení, umožňují vysoce kvalitní multiplanární reformátování obrazu pro 3D hodnocení anatomických struktur. Na rozdíl od 3D GRE sekvencí, 3D rychlé SE sekvence poskytují dobrou reprezentaci abnormalit subchondrální kosti. Až do současnosti 3D rychlé SE zobrazování nebylo nahrazeno rutinním 2D rychlým zobrazováním. [64-66]

2.3.5 SPGR zobrazování


3D SPGR zobrazování je považováno za standardní techniku pro morfologické hodnocení kolenní chrupavky, protože disponuje vysokou senzitivitou než 2D techniky a poskytuje excelentní reprezentaci defektů chrupavky v porovnatelné kvalitě jako je tomu u artroskopie. U 3D SPGR zobrazování transversální stabilní stav je narušen polo náhodnými alternacemi ve fázi radiofrekvenčního pulzu pro získání kontrastních podobností, jako je tomu u T1 váženého obrazu, nebo zobrazování na základě vážené protonové hustoty. SPGR sekvence je dostupná u většiny MR zobrazovacích systémů a je užitečná, když hodnocení chrupavky je vyžadováno. SPGR zobrazování zvyšuje signálovou intenzitu chrupavky ve vztahu k přilehlým strukturám a kloubnímu obsahu, jako je tekutina. Tato technika navíc umožňuje akvizici téměř izotropních voxelů, poskytujících vysoké rozlišení 3D obrazů, které jsou ideální pro vyhnutí se parciálním objemovým artefaktům a dosažení přesné kvantitativní posouzení tloušťky a objemu chrupavky. Potlačení lipidů je často dosaženo na základě využití metody potlačení tuku, ale může být také dosaženo na základě excitace vody. Tato metoda byla prokázána jako užitečná v oblasti detekce rizikových faktorů progresu ztráty chrupavky. [67-69]

Tato technika má několik nevýhod. Malé fokální léze mohou být nezřetelné, protože nedisponují dostatečným kontrastem mezi chrupavkou a tekutinou, která vytváří kontury defektů chrupavky. Tato technika je nespolehlivá pro posouzení kolenních struktur, jiných než je artikulární chrupavka. Efekt tzv. magického úhlu může vést k falešně pozitivním nálezům v oblasti ligament a menisků a efekt magnetické susceptibility může vést k nezřetelnosti kostních abnormalit. Dlouhý akviziční čas může vést k pohybovým artefaktům a méně přesným měřením. Tato technika je rovněž vysoce náchylná k artefaktům susceptibility. V recentních studiích obrazy artikulárních chrupavek s vysokým rozlišením jsou generovány se zvýšeným SNR, kde je dosaženo vyššího kontrastu mezi chrupavkou a tekutinou a také je dosaženo krátkého akvizičního času v kombinaci IDEAL a SPGR sekvencí, než je tomu u standardní SPGR sekvence s potlačením tuku. [70-72]



Obrázek 18 Koronární 3D SPGR obraz ukazuje intaktní povrch chrupavky s vysokou intenzitou. Potlačení lipidů poskytuje excelentní kontrast mezi chrupavkou a subchondrální kostí. [54]

Jedním z typů SPGR sekvence je tzv. Fast Low-Angle Shot (FLASH) zobrazování, u kterého náhodný gradientní pulz je využit k produkci fázového posuvu k dosažení vážené protonové hustoty, nebo T1 váženého rozlišení. FLASH technika je akceptovatelnou technikou morfologického posouzení artikulární chrupavky. Navíc se tato technika uplatňuje pro posouzení časové změny tloušťky a objemu chrupavky. Potlačení lipidů je obvykle docíleno na základě přídavné techniky potlačení tuku, nebo pulzů pro excitaci vody. Fyziologická chrupavka disponuje vysokou signálovou intenzitou na FLASH obrazech, povrchové léze jsou lépe viditelné a diagnostikovatelné. Na druhou stranu tyto léze mohou tvořit překážku pro detekci defektů artikulární chrupavky, jako jsou např. fisury. FLASH technika umožňuje akvizici obrazů s vysokým prostorovým rozlišením, ale dlouhý akviziční čas může vést k pohybovým artefaktům. Navíc tato technika je náchylná k artefaktům susceptibility, které mohou vést k podcenění škály kostních změn. Nicméně FLASH zobrazování je užitečné pro volumetrická hodnocení kolenní chrupavky po reparacích ve spojení s technikami jako je autologní implantace chondrocytů. [72]



Obrázek 19(a) Koronární T2 vážený obraz s potlačením tuku ukazuje velké oblasti kompletní ztráty chrupavky v mediální tibiofemorální oblasti s degenerativními lézemi v subchondrální kosti (hrot šipky). Velké osteofyty a mediální extrukce jsou rovněž viditelné. (b) Koronární 3D FLASH obraz přesně reprezentuje oblasti kompletní ztráty chrupavky v mediální části, jako je tomu v obraze (a). [54]

2.3.6 DEFT zobrazování


DEFT zobrazování je založeno na aktivním návratu magnetizace do z osy po každé excitaci. Tato metoda zvyšuje kontrast mezi tekutinou a chrupavkou vylepšením signálu synoviální tekutiny, zatímco signál z chrupavky je ponechán. Protože DEFT zobrazování využívá krátký TE, signálová intenzita tekutiny je vyšší, než je tomu u SPGR zobrazování, a intenzita signálu chrupavky je vyšší, než je tomu u T2 váženému rychlému SE zobrazování. Kontrast mezi tkáněmi je závislý na poměru T1 k T2 v každé tkáni a kontrast chrupavky k tekutině je vyšší s krátkou TR u DEFT zobrazování, než je tomu u zobrazování váženou protonovou hustotou. Potlačení lipidů je často dosaženo na základě pulzu, který potlačuje tuk. Diagnostický výkon s technikou DEFT zobrazování v oblasti detekce lézí chrupavky je porovnatelný se standardními 2D technikami a SPGR sekvencemi. Nevýhodou techniky DEFT zobrazování je náchylnost k pohybovým artefaktům kvůli dlouhým akvizičním časům. Tato technika rovněž poskytuje neadekvátní saturaci tuku a je nesenzitivní ke strukturálním změnám kostí, jako jsou edémy, což může vést k podcenění kostních lézí. [73, 74]



Obrázek 20 Sagitální 3D DEFT obraz demonstrující fisury chrupavky (šipka). Defekt je vymezen na základě vysoké signálové intenzity synoviální tekutiny. [54]

2.3.7 DESS zobrazování

U techniky DESS zobrazování jsou vyžadovány dvě, nebo více ech. V závislosti na parametrech, které jsou využity pro získání 3D DESS obrazů, je formován kontrast obrazu. Kontrast mezi povrchem chrupavky a synoviální tekutiny může být značně slabý, aby bylo možné načrtnout drobné defekty chrupavky. Nicméně zvýšením flip úhlu je kontrast mezi chrupavkou a synoviální tekutinou značně zvýšen a je dosažena lepší reprezentace drobných lézí chrupavek. Potlačení lipidů může být dosaženo na základě potlačení tuku, nebo technikou excitace vody. Protože akviziční čas DESS zobrazování je kratší, než je tomu u 3D SPRG zobrazování, tato metoda je méně náchylná na obrazové artefakty, způsobené patientským pohybem, a tak pravděpodobněji poskytuje přesné měření. Technika rovněž poskytuje relativně větší SNR, vyšší kontrast chrupavky vůči synoviální tekutině a navíc umožňuje redukci parciálních objemových efektů. Protože chrupavka disponuje vysokou signálovou intenzitou, interní změny signálové intenzity chrupavky mohou být obtížně detekovatelné touto technikou. V oblasti kolenní osteoartritidy 3D DESS technika umožňuje kvantitativní posouzení tloušťky a objemu chrupavky s dobrou přesností. V porovnání s ostatními 3D GRE technikami, které jsou testovány pro podélné kolenní osteoartritidy, DESS zobrazování se projevuje podobnou senzitivitou pro časově proměnnou tloušťku chrupavky. Nicméně schopnost této techniky pro posouzení přilehlých struktur jako jsou menisky a vazy nebyla dosud validována. [54, 75]



Obrázek 21 Segmentace 3D DESS obrazových dat, získaných v koleni. (a, b v rozdílných plánech) poskytují kvantifikaci chrupavky ve femorálních kondylech (červená a žlutá), tibiální plošiny (tmavě modrá a zelená), trochlea (světle modrá) a patella (fialová). [54]

2.3.8 bSSFP zobrazování

U 3D bSSFP zobrazování je situace podobná jako je tomu u 3D DESS zobrazování, chrupavka je zobrazena s vysokou signálovou intenzitou, ale parametry jsou odlišné od těch, které jsou použity u metody DESS. [54]

3D bSSFP zobrazování reprezentuje tekutinu se zvýšenou signálovou intenzitou, zatímco signálová intenzita chrupavky je zachována. Metoda poskytuje excelentní kontrast mezi synoviální tekutinou a chrupavkou. Diagnostický výkon 3D bSSFP zobrazování je obdobný jako je tomu u standardních 2D sekvencí a běžně využívaných 3D GRE sekvencí pro morfologické posouzení kolenní chrupavky. Technika je rovněž využitelná pro zobrazování ostatních interních struktur kolena, jako jsou ligamenta a menisky. Tato vlastnost dělá techniku atraktivní pro širokou využitelnost v klinické praxi. [54]

Varianta metody bSSFP, která se nazývá „fluctuating equilibrium MR“ je využitelná pro morfologické hodnocení kolenní chrupavky. Metoda generuje 3D obrazy s krátkým akvizčním časem. Tato technika rovněž poskytuje dostatečný kontrast mezi chrupavkou a tekutinou, který závisí na poměru T1 ku T2 v těchto tkáních. Metoda poskytuje vyšší SNR v chrupavce oproti standardním technikám jako vážená protonová hustota SE, T2 vážená rychlá SE a 3D SPRG zobrazování. [54]


Pokročilejší alternativa bSSFP sekvencí aplikovaných v kombinaci s technikou separací vody a tuku dávají naději pro redukci akvizčního času pro morfologické posouzení kolenní chrupavky. Nicméně nebyly dosud publikovány klinické studie v oblasti kolenní osteoartritidy, nebo reparací kolenní chrupavky na základě zobrazování metodou 3D bSSFP. [76, 77]



Obrázek 22(a) Sagitální 3D excitace vody, bSSFP zdrojový obraz ukazuje fokální parciální tloušťku defektu chrupavky (šipka) v mediálním femorálním kondylu. **(b)** Věněný přeformátovaný obraz ukazuje defekty (šipky). [54]

2.3.9 VIPR zobrazování


VIPR-SSFP představuje recentní techniku, která je založena na kombinaci bSSFP zobrazování s 3D radiální akvizicí k-prostorem, umožňující akvizici obrazů s izotropním prostorovým rozlišením a T2/T1 váženým kontrastem. Radiální akviziční technika poskytuje efektivnější vyplňování k prostoru sbíráním dvou radiálních linií a vynecháním defázovacích frekvencí a refázovacích gradientních pulzů. Lineární kombinace bSSFP je využita k separaci tukového signálu ze signálu vody. VIPR zobrazování poskytuje izotropní 0.5-0.7 mm tloušťku vrstvy 3D obrazové sekce, umožňující přeformátování v libovolně zvoleném plánu. Tato metoda dosahuje vysokého SNR v chrupavce a vysokého kontrastu mezi chrupavkou a přilehlých kloubních strukturách. Krátké akviziční časy usnadňují implementaci této techniky v klinické praxi a klinickém výzkumu. [54]



Obrázek 23 Sagitální zdroj (a) a koronální přeformátování (b) 3D VIPR-SSFP obrazy vykazují vysoké SNR u chrupavky a vysoký kontrast mezi chrupavkou, synoviální tekutinou a ostatními kloubními strukturami. [54]

2.3.10 SPACE zobrazování


SPACE zobrazování představuje 3D rychlou SE techniku, kde turbo faktory jsou generovány na základě tzv. restore pulzu a variabilní úhel rozložení je využit k produkci pseudo stabilního stavu. Tzv. refocusing pulz v metodě SPACE obsahuje variabilní flip úhel ($<180^\circ$) radiofrekvenčních pulzů, aplikovaných podél echa. Tato technika může poskytovat vysoký T2 vážený kontrast tkání. Navíc SPACE zobrazování může být získáno s izotropním prostorovým rozlišením, umožňujícím multiplanární reformátování. Při porovnání s 3D technikami, které jsou běžně využívány pro investigaci artikulární chrupavky, SPACE disponuje lepším SNR a vyšší SNR efektivitou. Diagnostický výkon je porovnatelný s metodou 3D DESS zobrazování, ale je horší, než je tomu u standardní metody 2D vážené protonové denzity SE techniky. Nevýhodou SPACE zobrazování je dlouhý akviziční čas. Navíc kontrast mezi chrupavkou a přilehlými tkáněmi není optimální. Tato technika doposud nebyla validována pro využití hodnocení artikulárních chrupavek a ostatních kolenních struktur, jako jsou menisky a vazy v klinické praxi. [78]



Obrázek 24 3D SPACE zobrazování přesně vymezuje chrupavku v mediálním femorálním kondylu (hrot šipky) a trhlinu posteriálního rohu mediálního menisku. [54]

2.3.11 Kompozitní zobrazování chrupavky

Hyalinní artikulární chrupavka je složena z tekuté makromolekulární sítě, která podporuje mechanické zatížení. V průběhu zatížení kloubu je elektrolyt obsahující intersticiální tekutinu, která reprezentuje okolo 75% objemu chrupavky, tlačěn do té míry, že pohyb je omezen makromolekulární sítí, která distribuuje a podporuje mechanické zatížení. Makromolekulární síť obsahuje hlavně kolagen a proteoglykany. Kolagen je nejhojnější makromolekula, tvořící okolo 20% objemu chrupavky. V normálním kloubu kolagenní síť působí na strukturální rámec tkání, poskytující hlavní zdroj tahu a síly. Uspořádaná kolagenní síť a asociovaný obsah vody způsobuje magnetický přenos a také artefakty úhlu magnetizace. MR zobrazovací techniky, které jsou dostupné pro posouzení fyziologické kompozice artikulární chrupavky v kolenu a jejich aplikace v klinické praxi jsou popsány v následující sekci. [54]



Obrázek 25 T2 mapy, získané v artikulární chrupavce u 51 letého muže po reparaci vazů ukazuje vyšší T2 hodnoty (žlutá) v mediálním (a) a laterálním (b) tibio-femorálním kompartmentu, nálezy indikující zhoršení integrity a orientace kolagenní sítě. Mapy jsou získány MR 3T s sagitální 3D T2 váženou SE sekvencí. [54]

2.3.11.1 T2 mapování

T2 hyalinní artikulární chrupavky reflektuje interakce mezi vodními molekulami a přilehlými makromolekulami a je vysoce senzitivní ke změnám matice chrupavky. T2 je vysoce senzitivní ke změnám v hydrataci, nebo je blízce ekvivalentní ke koncentraci kolagenu a v normální anizotropní orientaci kolagenních vláken v průběhu extracelulární matice chrupavky, což je výsledkem fyziologických, nebo patofyziologických procesů v chrupavce. [78, 79]


V normální chrupavce regionální a zónové diference v denzitě a organizaci kolagenní matice jsou variabilní v T2. Multi echo SE techniky je využito pro měření T2 hodnot. Relevantním důkazem, že T2 mapování je využitelné pro identifikování oblastí raných degenerací (rané narušení kolagenní matice) v chrupavce, které se jeví jako oblasti s vyšším T2, než je tomu u normální chrupavky. V porovnání s T2 hodnotami u normální hyalinní chrupavky, tyto nálezy v osteoartritické chrupavce jsou více heterogenní. Rutinní MR zobrazování umožňuje subjektivní posouzení změny T2 chrupavky, naproti tomu kvantitativní T2 mapování poskytuje objektivní data, generovaná buď barevnou, nebo monochromatickou mapou reprezentující variace relaxačního času v průběhu chrupavky. [80]

Důkazem je, že T2 mapování je užitečné pro identifikování sítí raných degenerací (rané přerušení kolagenní matice) v chrupavce, které se jeví jako oblast s vyššími T2 hodnotami, než je tomu u normální chrupavky. V porovnání s T2 hodnotami normální chrupavky jsou tyto nálezy v osteoartritické části chrupavky více heterogenní. [81, 82]

Zvýšený T2 je běžně více asociován s poškozením chrupavky, nicméně v některých případech může být pozorovatelná nízká signálová intenzita, která může vzniknout kvůli zvýšené interakci vody s molekulárními fragmenty v chrupavce. Ačkoliv T2 mapy mohou být využity pro diferenciaci normálních oblastí chrupavky od oblastí, kde dochází k degeneraci, není zde patrný lineární vztah mezi T2 a osteoartritidou. Navíc se zdá, že fyzikální aktivita hraje roli v T2 hodnotách chrupavky. [82]

T2 mapy mohou být využity pro monitorování časové efektivity reparací artikulární chrupavky. V rámci studií, které se zabývají variantními technikami reparací artikulárních chrupavek, T2 mapování představuje slibnou alternativu pro časové monitorování změn v artikulární chrupavce.


T2 mapování může být relativně jednoduše implementováno na většině klinických zobrazovacích systémů, jako jsou pulzní sekvence pro získání kvantitativních T2 map a software pro generování barevných T2 map, který je již komerčně dostupný. [83, 84]



Obrázek 26(a) Předoperační sagitální 2D obraz kolenní oblasti, získaný na základě protonové denzity s potlačením tuku 20leté ženy demonstruje značný osteochondrální defekt mediálního femorálního kondylu (šipky) s subchondrální cystickou formací (hrot šipky). **(b)** Pooperační sagitální 2D obraz kolenní oblasti, získaný na základě protonové denzity s potlačením tuku, získaný 18 měsíců po autologním chondrocytickém implantátu ukazuje heterogenní reparaci tkání (šipky) a jemný dřevový edém (hrot šipky). **(c)** Sagitální T2 mapa, získaná na základě multiecho sekvence ve stejném čase jako (b) poukazuje na oblasti tkáňové reparace s heterogenní T2 signálovou denzitou (šipky). [54]

2.3.11.2 Technika dGEMRIC

Technika je založena na pozorování, kdy ionty intersticiální tekutiny v hyalinní chrupavce jsou distribuovány ve vztahu ke koncentraci k negativně nabitým glykosaminoglykanovým molekulám, které jsou dle pořadí příbuzné k množství proteoglykanu. V oblasti techniky dGEMRIC je využíván termín „delayed“, který koresponduje s časem, který je potřebný pro umožnění penetrace Gd-DTPA skrz plnou tloušťku chrupavky. Za normální situace se kloub pohybuje po dobu přibližně 10 minut po administraci Gd-DTPA a poté je provedeno měření T1 (90 minut po aplikaci injekce). [85]




Obrázek 27 Komparace indexu dGEMRIC, získaného u pacienta s kolenní osteoartritidou (a) a získaný obraz u zdravého subjektu. (a) ukazuje nižší indexovací hodnoty v (b), nálezy, reprezentující vyprázdnění glykosaminoglykanového obsahu v artikulární chrupavce (hrot šipky) a degenerace mediálního menisku. Škála je generována v milisekundách. [54]

Sekvence dGEMRIC je často generována s využitím 3D SPGR pulzní sekvence s variabilním flip úhlem (55), ale bSSFP, nebo jiné techniky s nízkým akvizčním časem a lepším SNR pro měření T1 a T2 rovněž mohou být využity. Variace v dGEMRIC indexu mohou být dokonce viditelné v průběhu fyziologické artikulární chrupavky v raném stavu osteoartrity, která je charakterizována redukcí koncentrace glykosaminoglykanu v hyalinní chrupavce. dGEMRIC index může být ovlivněn řadou fyziologických faktorů, jako jsou cvičení a body mass index, rovněž může být ovlivněn akutním psychickým stresem. dGEMRIC index byl validován v rámci klinických studií, kde byl komparován s referenčním standardem histologického a biochemického měření obsahu glykosaminoglykanu. dGEMRIC má ambice být neinvazivní metodou pro monitorování obsahu glykosaminoglykanu v chrupavce. [86]

Technika dGEMRIC může být jednoduše klinicky implementovatelná s využitím standardního 1.5, nebo 3T magnetu. Ačkoliv typický akvizční čas této metody je až dvě hodiny, což snižuje atraktivitu této metody pro účely klinické praxe, dGEMRIC má potenciální hodnotu v oblasti klinického testování, kde byla ukázána schopnost pro demonstraci změn v morfologicky neporušené chrupavce, což může sloužit jako indikátor predikce progresu osteoartrity. [87-89]

2.3.11.3 T1ρ zobrazování

T1ρ relaxační čas (trvání relaxace spinové mřížky v rotačním rámu) je obdobný k T2 relaxačnímu času. Nicméně pro měření T1ρ je aplikován přídatný radiofrekvenční pulz po překlopení magnetizace do transversální polohy. Je zde patrný vztah mezi T1ρ a změnou energie mezi spinujícími protony vody a jejich prostředím. [54]



Obrázek 28 Komparace T1ρ map, získaných v kolenní chrupavce u zdravého subjektu (a) a pacienta s vážnou osteoartritidou (b) ukazuje vyšší hodnoty T1ρ v (b). Střední hodnoty v mediálním femorálním kondylu byly 32,9 msec ± 9,0 v (a) a 49,1 msec ± 14,2 v (b). [54]


Interakce mezi molekulami vody s omezenou hybností a jejím lokálním makromolekulárním prostředím může být monitorována na základě měření T1ρ, což zapříčiňuje T1ρ slibnou techniku pro posouzení kompozice chrupavky, jelikož extracelulární mřížka poskytuje vhodné prostředí s omezením hybnosti pro molekuly vody. Tedy změny v extracelulární mřížce, jako je vyprázdnění proteoglykanu, mohou měnit hodnoty T1ρ, měřené v chrupavce. V osteoartritickém kolenu narušená hyalinní chrupavka je demonstrována vyššími hodnotami T1ρ oproti normální chrupavce. Navíc T1ρ disponuje vyšší senzitivitou oproti T2 váženému zobrazování pro diferenciaci mezi normální chrupavkou a počínající osteoartritidou, což je demonstrováno na obrázku 28.

T1ρ měření vyžaduje speciální pulzní sekvence, které jsou typicky dostupné pouze ve vědeckých institucích. Také vyžaduje časově náročné datové soubory, což dělá tuto techniku méně atraktivní pro oblast klinické praxe. [90-92]

Zobrazování sodíku

Sulfátové a karboxylové skupiny propůjčují negativní fixní hustotu náboje extracelulární mřížky v artikulární chrupavce. V souladu s principem elektrické neutrality, kladné ionty jsou distribuovány v koncentraci, která je ekvivalentní k denzitě negativní fixní hustoty náboje v průběhu extracelulární mřížky. Normální hyalinní chrupavka disponuje vyšší koncentrací sodíku a oblastmi chrupavky s vyprázdněním glykosaminoglykanu. Protože sodík disponuje čistým spinovým momentem, má specifickou rezonanční frekvenci, měřitelnou v MR zobrazování. [54]

Sodíkové MR zobrazování se ukazuje jako slibná metoda pro kompozitní posouzení artikulární chrupavky. Výhodou techniky je, že sodík se jeví neutrálně v mřížce chrupavky, signálová intenzita chrupavky je vyšší v komparaci s jejím pozadím. [54]



Obrázek 29 Celkový sodíkový MR obraz získaný na základě protonové vážené denzity SPGR sekvence u 20letého dobrovolníka ukazuje vyšší signálovou intenzitu v chrupavce v mediálním kompartmentu. Obraz byl pořízen 3.0 T s kvadrurní sodíkovou cívkou a 3D kužely, odečítající trajektorii s prostorovým rozlišením 1.25x1.25x4 mm a akvizčním časem 20 min. Stupnice je generována v mili molech. [54]


Zobrazování sodíku může být užitečné pro diferenciaci mezi ranými stádii degenerace chrupavky a normální chrupavkou. Kvůli krátkým T2 relaxačním časům sodíku je tato technika běžně implementována s využitím spektrálně vážené projekce. Měla by být věnována péče interpretaci MR sodíkovému zobrazování chrupavky, protože některé prostorové variace v sodíkové koncentraci (a tak v signálové intenzitě) mohou být přítomny v normální chrupavce. [93-95]

Protože SNR (a proto rozlišení) je signifikantně nižší u sodíkového MR zobrazování, než je tomu u protonového MR zobrazování, a protože je vyžadován speciální hardware, klinická implementace této techniky je obtížná a je dostupná pouze na úzce specializovaných pracovištích. Důležitým faktem je rovněž skutečnost, že byly provedeny rozsáhlé klinické studie, zabývající se využitím sodíkového MR zobrazování kolenní osteoartritidy, nebo reparací kolenní chrupavky. [93-95]

2.3.11.4 Difuzně vážené zobrazování

Difuzně vážené MR zobrazování je založeno na pohybu vodních molekul, které jsou ovlivněny intra a extra celulárními bariérami. Protože magnituda a směr lokální tkáňové difuzivity je ovlivněna makromolekulárním prostředím difuzního objemu vody, difuzně vážené zobrazování může poskytovat užitečnou informaci o tkáňové ultrastruktuře. [96]

Difuzní měření jsou získávána aplikováním mnohočetných difuzně senzitivních gradientních MR pulzů pro generování magnetizace ve vodních molekulách. Fáze magnetizace je potom reverzní. Náhodné množství magnetizace generované v mobilních vodních molekulách je ztraceno a nemůže být refokusováno, což vede ke ztrátě signálové intenzity ve tkáních, afektovaných difuzí. Difuze vody v artikulární chrupavce reflektuje biochemickou strukturu a architekturu tkání. Difuzní koeficient (ADC) je nízký pro dlouhé difuzní časy ve zdravé chrupavce, protože difuze vodních molekul je omezena komponenty chrupavky. Narušení mřížky chrupavky přispívá ke zlepšení vodní mobility, která zvyšuje ADC chrupavky. Tyto variace ADC hodnot v průběhu chrupavky a ostatních struktur mohou být mapovány. Tento fakt je zobrazen na obrázku 30. [96, 97]




Obrázek 30 Sagitální ADC mapa, získaná na základě difuzně váženého MR zobrazování v koleni u asymptotického 28letého muže ukazuje region vyšší signálové intenzity mediálního femorálního kondylu. Obraz byl pořízen 3.0 T (TR/TE=2200/73, b=600 sec/mm², tloušťka=5mm, mřížka=192x192). [54]

Jelikož difuzně vážené MR zobrazování nevyžaduje využití kontrastní látky a aplikace s aktuálními sekvencemi trvá okolo 5 minut, má tato metoda potenciál využití v klinické praxi. Nicméně nevýhodou této techniky je fakt, že neposkytuje striktně kvantitativní měření. Rovněž doposud nebyly provedeny rozsáhlé studie, zahrnující využití difuzně váženého MR zobrazování pro vyhodnocení kolenní osteoartritidy, nebo reparací kolenní chrupavky. [97]

2.3.11.5 MR zobrazování s variabilními silovými poli

Variabilní silová magnetická pole jsou dostupná pro využití v klinické praxi a klinickém výzkumu. Důležitým aspektem je fakt, jaká síla pole je nejlepší pro morfologické a kompozitní posouzení chrupavky. Nízká síla magnetického pole (0.18-0.2T) je neadekvátní pro morfologické posouzení artikulární chrupavky a rovněž není doporučena pro vyhodnocení kolenní osteoartritidy, nebo reparací chrupavky. Síla magnetického pole alespoň 1T je doporučena pro morfologické posouzení kolenní chrupavky. V oblasti rozsáhlého klinického testování kolenní osteoartritidy je využíváno 1.0T MR zobrazování, což prokazuje dobrou až excelentní intra a inter observační spolehlivost pro morfologické posouzení chrupavky, dokonce v porovnání se 1.5T zobrazováním. Aktuálním standardem pro zobrazování chrupavek je 1.5T, toto je síla magnetického pole, která je využívána v mnoha studiích MR zobrazování morfologického a kompozitního posouzení artikulární chrupavky. Nicméně 3.0T systémy demonstrují slibné výsledky pro optimalizaci morfologického a kompozitního zobrazování chrupavky. SNR u 3.0T je zhruba dvojnásobné, než je tomu u 1.5T, což umožňuje vylepšení obrazové kvality a prostorového rozlišení při obdobném akvizičním čase. Síla magnetického pole 3.0T umožňuje lepší morfologické hodnocení chrupavky, než je tomu u 1.5T. Na druhou stranu využití silnějších magnetických polí přináší nové výzvy. Magnetická susceptibilita v tkáních je zhoršená, uložená energie v podrobené tkáni je vyšší (4x vyšší, než je tomu u 1.5T), obrazy jsou více náchylné na plovoucí artefakty, což může být problém kolem kolenního kloubu. Přestože existuje několik center, které disponují 7.0T magnety, tyto modalitty jsou využívány pouze v oblasti klinického výzkumu. Síla magnetického pole 7.0T je využita v rámci studií posouzení morfologické a kompozitní kolenní chrupavky u lidí. Nicméně v současné době není prokázána nadřazenost protokolů 7.0T zobrazovacích systémů oproti 3.0T pro posuzování artikulární chrupavky. [98-103]



Obrázek 31 Komparace sagitálních 3D SPGR MR obrazů, získaných na 3.0T (a) a 7.0T (b) v oblasti kolena u zdravého dobrovolníka neukazují výrazné difference v manifestaci artikulární chrupavky, ačkoliv artefakty, způsobené magnetickou susceptibilitou jsou zhoršené v silnějším magnetickém poli ve tkáních, jako je trabekulární kost (hrot šípky v (b)). [54]

3 Segmentační metody artikulárních chrupavek z MR

Stěžejním cílem této kapitoly je poskytnutí ucelených recentních informací ohledně matematických segmentačních technik, které se zabývají extrakcí artikulárních chrupavek z MR. V rámci rešerše jsou rámcově popsány jednotlivé segmentační techniky, včetně aplikačních výstupů na reálných klinických MR datech artikulární chrupavky.

3.1 Segmentační metody kolenního kloubu

Segmentace obrazu je definována separací obrazového záznamu na vzájemně se nepřekrývající disjunktí regiony, které jsou homogenní s ohledem na charakteristiky, jako je obrazová intenzita, nebo textura. Každá segmentační metoda hledá takovou množinu, která koresponduje s odlišnými anatomickými strukturami, nebo regiony zájmu v analyzovaném obrazu. Jestliže obrazová doména je dána označením Ω , potom segmentační problém určuje množinu $S_k \subset \Omega$, jehož unie reprezentuje celkovou doménu Ω . A tak množiny, generující segmentační výstup musí splňovat:

$$\Omega = \bigsqcup_{k=1}^K S_k \quad (3.1)$$

Kde $S_k \cap S_j = \emptyset$, pro $k \neq j$. Segmentace kolenního kloubu je velice aktuální oblast, zejména kvůli kloubní komplexitě. [103-105]

3.2 Přehled

Kvalitativní posouzení kolenní oblasti je pouze schopné identifikovat progresi onemocnění v pozdějších stádiích. Recentní studie ukazují, že je možné predikovat degeneraci artikulární chrupavky na základě monitorování chrupavky v průběhu času. Primární cíl monitorování zahrnuje mapování tloušťky artikulární chrupavky, objem a analýzu povrchu. Aby bylo možné provést exaktní měření zmiňovaných parametrů, je nezbytné modelovat strukturu artikulární chrupavky na základě segmentačních metod zpracování obrazu s cílem extrakce a lokalizace její manifestace z klinických záznamů. [105]

Mohou existovat nejrůznější důvody pro vizualizaci artikulární chrupavky, nejběžnějším je však prevence osteoartritidy. Mohou to být např. studie, nalézající variace ve struktuře artikulární chrupavky v průběhu analyzovaných populačních skupin. Důležitým typologickým výstupem analýz je rovněž schopnost rozlišení struktury artikulární chrupavky s využitím variabilních MR modalit. Tyto studie bývají nápomocné pro určení optimálních akvizičních parametrů pro precizní odhad objemu chrupavky. [105-109]

3.3 Manuální segmentace artikulárních chrupavek

Předešlé studie ukázaly, že vývoj plně automatických algoritmů pro segmentaci artikulární chrupavky nepředstavuje triviální úkol. Až doposud se ukazuje, že manuální obrys hranic artikulární chrupavky expertem patří mezi nejběžněji používanou techniku. Je to značně pracný a časově náročný postup, který může představovat časovou zátěž několika hodin pro analýzu jednoho kolenního záznamu, v závislosti na velikosti obrazu, kvalitě a stavu onemocnění konkrétního pacienta. Navíc tato metoda postrádá relevantní reprodukovatelnost, zapříčiněnou lidskou chybou a rovněž vyžaduje

speciální trénink. Nicméně, žádný z existujících (semi)automatických algoritmů nebyl schopen poskytnout vizuálně kvalitní výsledky, a tak manuální segmentace stále přetrvává jakožto zlatý standard pro validaci segmentačních algoritmů. [110, 111]

3.4 Automatická segmentace artikulárních chrupavek

Z praktického hlediska vždy musí být dodržena balance mezi výkonem algoritmu, přesností, robustností a úrovní lidské interakce. Ideální segmentační algoritmus by maximalizoval preciznost a přesnost pro rozsáhlé variantní obrazové výstupy a zároveň by omezoval interakci uživatele na minimum. Hlavním cílem je vývoj plně automatického segmentačního algoritmu, disponujícím vysokou přesností lokalizace chrupavky, specifitou, reprodukovatelností a robustností a rozumným výpočetním časem. Tento úkol je komplikovaný díky mnoha dílčím faktorům. [112, 113]

Vrstva artikulární chrupavky je velice tenká, v některých oblastech tloušťka dosahuje až submilimetrových úrovní. Je proto vyžadováno, aby bylo dosaženo co nejrelevantnější segmentace, kde jako zdroj lze využít pouze MR obrazy, disponující vysokým rozlišením, ačkoliv je tento požadavek spojen s relativně vysokým akvizičním časem. S narůstajícím časem, který pacient stráví v gantry, stoupá riziko nechtěných patientských pohybů, které zapříčiňují obrazové artefakty, které představují významný problém z hlediska klasifikace oblastí artikulární chrupavky a diferenciací okolních tkání.

Rovněž bývá problémem dosažení dostatečného kontrastu mezi artikulární chrupavkou a okolními tkáněmi, obzvláště kostmi. Dokonce i po potlačení tuku je hranice mezi chrupavkou a vazy, nebo tukovými tkáněmi velice vágní. Důležitým faktem, který je potřeba zmínit, je skutečnost, že tkáň samotné chrupavky v celém jejím průběhu není homogenní. Algoritmus by proto měl být trénován pro rozpoznání těchto vzorů, aby bylo dosaženo maximální robustnosti. Obrazový šum je další faktor, který má přímý efekt na výstup segmentace. Platí jednoduchá zásada, která poukazuje na fakt, že relevance kvality segmentace je závislá na kvalitě vstupních obrazových dat. [112, 113]

Segmentace chrupavky je komplexní proces, ke kterému je typicky přistupováno sekvenčním přístupem. Přístup je standardně řešen v několika krocích. Například pokud některá ze segmentačních komponent selže, protože není možné pracovat pouze s určitým typem vstupních dat, konkrétní část řešení by byla nahrazena výhodnější a robustnější alternativou. Kromě toho, některé komponenty rovněž mohou, ale nemusí, vyžadovat interakci uživatele. Tento fakt nutně neznamená, že uživatel musí být trénován pro využití softwarové metody, ale na druhou stranu by měl být permanentně pod supervizí a výstupy by měly být konfrontovány s odborníky z klinické praxe. Nicméně z hlediska efektivity, algoritmus by měl, pokud možno, pracovat autonomně, bez uživatelské intervence. Jedním z typických problémů automatických segmentačních metod je nedostatečná robustnost, zapříčiněná variabilními typy analyzovaných obrazových dat. [112, 113]

3.5 Validací metrika

Segmentační algoritmy jsou standardně validovány, pokud to situace dovoluje, na základě zlatého standardu, což představuje rámcový výstup, generovaný expertem vzhledem ke konkrétní segmentační metodě a informacím, kterých by mělo být ideálně dosaženo. Míra úspěchu algoritmu je definována jako poměr výstupů, akceptujících vyžadovaná kritéria vůči totálnímu počtu případů. [114]

Pearsonův korelační koeficient r popisuje lineární korelaci dvou proměnných. Je kalkulován na základě poměru kovariance proměnných, vynásobených jejich směrodatnými odchylkami:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \cdot \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (3.2)$$

Pozorovaná variabilita je často měřena na základě výpočtu variačního koeficientu C_v , který je definován jako poměr směrodatné odchylky od výsledku k průměru:

$$C_v = \frac{\sigma}{\mu} \quad (3.3)$$

Simultánní pravdivost a úroveň odhadu (STAPLE) jsou běžnými technikami pro hodnocení přesnosti segmentace, v případě dostupnosti zlatého standardu, nebo v případě reprodukovatelnosti segmentačních výstupů experty. [114, 115]

3.6 Poloautomatická segmentace artikulárních chrupavek

Poloautomatické segmentační metody jsou zacíleny na redukcii uživatelských interakcí v průběhu segmentačního procesu, poskytující určitý stupeň supervize, aby byl algoritmus směřován korektním směrem. Poloautomatické metody běžně vyžadují inicializaci, čímž je míněno, že po uživateli bude vyžadováno specifikovat mezníky obrazových parametrů, jakožto startovací fáze segmentace. Poloautomatické segmentační metody mohou být rozděleny do následujících skupin:


- Intensity-based, thresholding, watershed
- Edge detection
- Energy-minimization: Live Wire, graph-cuts, active contours

3.6.1 Intensity-based segmentace

V tomto přístupu je provedena manuálně extrakce oblasti zájmu na základě počítačové myši, separátně pro každý obrazový řez MR. Software určuje střední intenzitu ve specifickém regionu a uživatel může specifikovat práh mezi směrodatnými odchylkami na základě střední obrazové intenzity. Všechny voxely, které mají intenzitu větší než stanovený práh, jsou klasifikovány jako region artikulární chrupavky. Tento algoritmus je validován na fyziologickém vzorku, který obsahuje dvě patologické kolenní oblasti bez známek osteoartritidy a čtyři pacienty, u nichž je plánována plná kolenní plastika (náhrada kolenního kloubu protézou). Krok prahování spoléhá na střední intenzitu, kalkulovanou z volumetrické oblasti zájmu. Proto je metoda senzitivní na lokální distribuci intenzit. Pokud se stane, že oblast obsahuje více kostí, které představují nižší voxelové intenzity, střední intenzita by byla k tomuto jevu náchylnější. Tloušťka vrstvy je v některých případech větší, typicky až 3.5 mm, z čehož může potenciálně vyplývat značná chyba přesnosti.

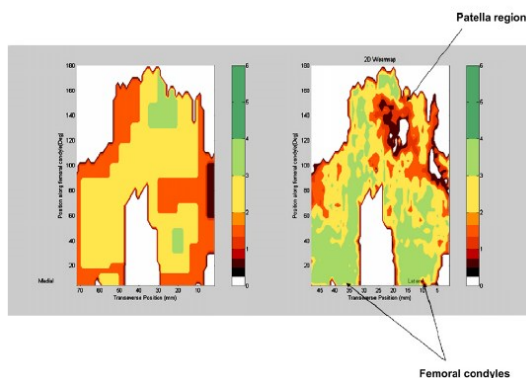
Další modalitou je modifikovaná verze tzv. watershed transformace. Obraz je v prvním kroku vyhlazen za využití anizotropního filtru, následovaného manuální anotací třech typů tzv. semínek (seeds): kost, chrupavka a ostatní tkáň (vazy, svaly, atd.). Užitím daných semínek, jakožto lokálních minim se algoritmus pokouší nalézt intersekcí tzv. povodí (catchment basins), regionů, které jsou umístěny proti proudu lokálního minima. Typickým problémem watershed metody je tzv. oversegmentation, která spočívá v aplikaci tzv. geodetické rekonstrukce. Namísto využití gradientního

obrazu jakožto vstupu pro watershed transformaci autoři představují funkci, která kalkuluje pravděpodobnost nalezení hrany mezi tzv. popsány a nepopsány voxely.



Obrázek 32 Nalezená hranice chrupavky, pomocí N generovaných paprsků od středního bodu a nálezu gradientu. [119]

Autoři tvrdí, že intenzity mezi rozličnými tkáněmi disponují normálním rozložením a vnitřně projevují prostorovou homogenitu. Tento fakt je nápomocný v případě repetice studie s využitím rozličných zobrazovacích sekvencí, aby bylo možné testovat robustnost metody.



Obrázek 33 2D mapa opotřebenosti artikulární chrupavky pacienta s osteoartritidou (vlevo) a normálního subjektu (vpravo). Arteficiální barevná mapa koresponduje s tloušťkou chrupavky od nejnižší hodnoty (černá) až po nejvyšší (zelená). [119]

Algoritmus je validován na vzorku manuálních segmentací, definovaných nezávisle dvěma experty. Přesnost poloautomatické segmentace je stanovena jako relevantní k manuální segmentaci. V inicializační fázi je nutné definovat 50 semínek pro každou klasifikační třídu, což zabírá 5-10 minut pro dílčí datový vzorek. Zatímco počítačová náročnost tohoto přístupu je signifikantně nižší, než je tomu v případě manuální segmentace (2 hodiny pro datový vzorek), mohlo by se zvážit testování algoritmu s nižším počtem semínek, nebo selekcí semínek automaticky. Rovněž by mělo být poznamenáno, že geodetická rekonstrukce vyhledá všechna povodí, která nebyla označena, a tak je důležité zvažovat lokace umístění semínek. [116-118]


3.6.2 Segmentace na základě detekce hran

Hranová detekce umožňuje vizualizaci tloušťky artikulární chrupavky 3D mřížkou (3D mesh). Ačkoliv není prioritním cílem provádět segmentaci artikulární chrupavky v rámci této analýzy, metoda spoléhá na přesný náčrt hranic artikulární chrupavky. Algoritmus je implementován v prostředí MATLAB. V prvním kroku uživatel specifikuje oblast zájmu (RoI) v okolí femorální chrupavky pro každý řez. Selektované RoI může být rovněž aplikováno i pro následující řezy v případě, že oblast chrupavky se v těchto oblastech manifestuje. Od specifického středového bodu je počet paprsků projektován ve směru RoI s krokem 4° . Každá linie je hledána, dokud hranice chrupavky není plně identifikována s využitím hranové detekce. Hranové body jsou kombinovány v 3D mřížce s využitím tzv. B-spline interpolace. V posledním kroku je měřena tloušťka chrupavky převzetím šířky mřížky podél normál k hranicím mezi kostí a chrupavkou. Přesnost algoritmu je hodnocena komparací výsledné segmentace s manuálně stanovenými konturami.

Algoritmus je testován pouze na femorální chrupavce zdravých jedinců a nejsou získány informace o výtěžnosti algoritmu v případě artritické chrupavky. Algoritmus také spoléhá na pečlivou selekci oblastí zájmu, aplikovanou individuálně na každý řez, a proto je tato metoda relativně značně náročná. Metoda postrádá robustnost, jelikož je pravděpodobné, že detekované hrany plně nekorespondují s hranicemi artikulární chrupavky, zejména z důvodu nižší kvality obrazových dat a rovněž nízkým kontrastem mezi tkáněmi v rámci dané obrazové sekvence. V budoucnu by bylo zajímavé pozorovat variabilitu výsledků, jelikož studie byla pouze validována jedním expertem.

Další studie, opírající se o detekci hran, kde uživatel definuje množinu bodů v rámci řezu chrupavky, je kombinována s tzv. Bezier splines. Algoritmus hledá rozhraní mezi kostí a chrupavkou a chrupavčité rozhraní s využitím následující procedury. Nejdřív je aplikována filtrace na základě tzv. anizotropní difuze s rozlišnými parametry pro každé rozhraní. Poté je projektován počet paprsků 15 voxely směrem pryč ze splinu a je brána maximální hodnota první derivace, která indikuje hranici chrupavky. V některých částech chrupavky, jako je např. tibio-femorální, nebo patelo-femorální rozhraní, nejsou hrany čistě detekovatelné. Z tohoto důvodu je aplikováno extra předzpracování obrazu. Obraz je opětovně zpracováván s využitím anizotropní filtrace s velmi slabým vyhlazovacím faktorem a hrana je extrahována ještě jednou s využitím bodů podél chrupavky, kde tloušťka chrupavky je větší než průměr $+ \frac{1}{4}$ směrodatné odchylky. V případě nenalezení směrodatné odchylky, předchozí hrana je považována za finální. Kosti jsou segmentovány podobným způsobem, jako je tomu u chrupavky s využitím rozhraní mezi kostí a chrupavkou, definovaného v předchozím kroku. Výsledné spliny jsou kombinovány a maska je interpolována lineárně s využitím distančních polí.

Algoritmus využívá několik pevných parametrů, např. hledanou vzdálenost podél paprsků, maximální prahovací intenzitu chrupavky atd. Navzdory relevantním výsledkům této studie a využívání zmiňovaných parametrů negarantuje optimální výsledky pro rozmanitější typy vstupních obrazových dat. V budoucnosti by inicializace těchto proměnných měla být dána automaticky s využitím statistických metod. Navíc by tato metoda, separující tibiální a femorální chrupavky, potřebovala vylepšit, jelikož distribuce intenzit jsou velice podobné a hranice jsou extrémně nečitelné. V rámci studie je rovněž kalkulován Personův korelační koeficient mezi přesunem vody artikulární chrupavky a jejím segmentovaným objemem: $r=0.83$.



Obrázek 34 Segmentace femorální chrupavky. (a) Bezier splines, generované z kontrolních bodů. (b) Liniový profil pro nalezení rozhraní mezi kostí a chrupavkou. (c) Liniové profily pro nalezení povrchu artikulární chrupavky. (d) Rozhraní mezi kostí a chrupavkou (tyrkysová barva) a povrch artikulární chrupavky (červeně anilínová barva) jako výsledek segmentace. [112]

Další alternativou hranové detekce je algoritmus, který zahrnuje větší kombinovaný počet separovaných filtrů, detekující hrany. Jednotlivé filtry jsou laděny pro každý typ artikulární chrupavky. Uživatel specifikuje tzv. seed point na rozhraní mezi kostí a chrupavkou a algoritmus se následně pokouší segmentovat chrupavku s využitím hranové detekce separátně pro hranové přechody kost-chrupavka a chrupavka-měkká tkáň. Uživatel může konsekventně intervenovat korekci chyb, takže struktura modifikuje tvar s využitím přístupu aktivních kontur. Segmentovaný tvar může být převeden do následujícího řezu a následně optimalizován pro následující řez, opětovně s využitím aktivních kontur. Popsaný proces je opakován, dokud 4 podseky kolenní chrupavky (tibiální chrupavka je považována za 2 separátní části) jsou segmentovány. Algoritmus vyžaduje, aby bylo využito 4 z 20 zlatých standardů segmentace pro trénování.

Autoři poskytují široký soubor nástrojů pro manipulaci v rámci segmentačního procesu. Nicméně tento proces vyžaduje trénink, jak je zmíněno v průběhu analýzy metody. Čas, potřebný k vykonání segmentačního procesu, je úměrný k manuální segmentaci, a tak není zcela zřejmé, co je stěžejním benefitem této metody, v případě komparace s manuální segmentací. Na druhou stranu autoři si jsou jistí, že čas segmentace bude redukován o 10-20 minut na jeden záznam.

Jemně modifikovanou verzí této metody je využití longitudinální studie, obsahující 24 měsíční datový vzorek, na jehož základě jsou chrupavky segmentovány a konsekventně komparovány. Pro segmentaci chrupavek je uživatel instruován, aby specifikoval dva 10mm cirkulární regiony, usazené na hrotu chrupavky, kde jakékoliv segmentační chyby mohou být ignorovány. Hranice artikulárních chrupavek jsou segmentovány jako v předchozím případě. Na základě překrytí segmentačních výstupů a vzájemnému odečtení je možné vizualizovat ziskové a ztrátové mapy a rovněž odhadovat volumetrické změny. [110, 119, 120, 121]

3.6.2.1 Segmentace patelární chrupavky na základě sub-pixelové detekce

Segmentové regiony každého z řezů jsou popsány jejich tzv. sub-pixelových hranic. Hranice jsou reprezentovány sekvencí fragmentů. V rámci prezentované metodiky je důležitým krokem předzpracování obrazu tzv. sub-pixelová hranová detekce v 2D prostoru, realizovaná separátně pro každý řez $s^z(x, y)$ s využitím tzv. fasetového modelu. Idea této metody spočívá v nalezení maxima v gradientním obraze:


$$g(x, y) = \left| \begin{pmatrix} s_x^z(x, y) \\ s_y^z(x, y) \end{pmatrix} \right| = \left| \begin{pmatrix} \frac{\partial}{\partial x} s^z(x, y) \\ \frac{\partial}{\partial y} s^z(x, y) \end{pmatrix} \right| \quad (3.4)$$

Což je získáno na základě využití Sobelova operátoru. V následujícím textu je princip objasněn pro jeden pixel (i, j) .

Na základě 3x3 sousedství pixelu (i, j) je gradientní obraz g lokálně aproximován polynomem druhého stupně dvou proměnných $p(x, y)$. Maximum polynomu p podél přímky, která je definována gradientním vektorem g , indikuje bod E na hraně v originálním obraze s . Jestliže se E nachází na hranici pixelu (i, j) , E je považováno jako hranový bod pro další zpracování. Rovněž je využit operátor $g(i, j)$, indikující ostrost hrany příslušného bodu. Popsaná procedura je aplikována na všechny pixely v každém řezu. Výsledkem je set hranových bodů a jejich příslušných ostrostí pro každý řez. Mezi definovanými body je konstruována řídicí kontura na základě předešlé kontury, pokud existuje. V jiném případě je jednoduše využito přímek.

Metoda rovněž poskytuje uživateli nástroj pro poloautomatické nalezení kontur pately. Uživatelská interakce je minimalizována vstupem startovacího bodu A a koncovým bodem B fragmentu kontury. Řídicí kontura je diskretizována sekvencí kontrolních bodů C_i .

Algoritmus je implementován do prostředí C++. V rámci studie je segmentován set MR obrazů fyziologické pately, získaných z FLASH sekvence. Autoři uvádějí, že na základě výsledků se poloautomatická propagace kontury jeví jako vysoce efektivní na rozhraní mezi kostí a chrupavkou. Nicméně v rámci studie není uvedena žádná komparace s jinými metodami, která by dokládala efektivnost navržené metody. [122]



Obrázek 35 Segmentace patelární chrupavky v jednom řezu se sub-pixelovou přesností. Fragment kontury ukazuje rozhraní mezi chrupavkou a kostí (nahore) a povrchem chrupavky (dole). Uzly v kontuře indikují hranové body, které byly určeny v rámci předzpracování obrazu. [122]

3.6.3 Segmentace využívající minimalizaci energie

V rámci techniky, označované jako Live Wire uživatel pohybuje počítačovou myší v okolí hran artikulární chrupavky, zatímco algoritmus kalkuluje v reálném čase nejlepší cestu v jejím okolí. Koncept metody využívá proceduru, minimalizující tzv. cost funkci, složenou z počtu elementů, které jsou inicializovány krátkou trénovací sekcí před započítáním samotné segmentace. V průběhu tréningu algoritmus automaticky kalkuluje hraniční omezení, získané z referenčního obrazu.

Uživatel začíná se selekcí tzv. semínkových bodů na hraně objektu a pohybuje myší ve směru kontury objektu. Algoritmus kalkuluje spojení, které zahrnuje několik vlastností, jako je intenzita obou hranových stran objektu, gradient ve směru rozlišené orientace a vzdálenost od předchozí hranice. V případě analýzy komplexnějších tvarů, segmentační proces může být generován několika kroky, kde semínkové body jsou položeny na začátek každé následující podsekcce. Algoritmus je validován na základě obrazového vzorku 4T skeneru. Objem chrupavky je měřen na základě tzv. dislokace vody. Aby bylo dosaženo precizního testování, proces je opakován na klinické výstupy pravého kolena zdravých dobrovolníků. Každý subjekt je skenován pětkrát, kdy koleno je fixováno. Chrupavky jsou segmentovány nezávisle třemi experty.

Přesnost výsledků je jen ztěží reprezentativní pro in-vivo nastavení, jelikož zobrazování je provedeno na fantomech. Navzdory tomuto nepříznivému faktu, autoři napodobili realistický klinický obraz generováním šumu a rozmazání, reálně musíme počítat s mnoha faktory, které přispívají k celkové obrazové kvalitě, což nelze být simulováno in vitro. Měření na fantomech jsou rovněž provedena jednou osobou. Dosažení statisticky signifikantních výsledků by jistě bylo dosaženo interesováním více expertů.

Nevýhodou je, že algoritmus je testován pouze na patelární chrupavce, disponující relativně pravidelným tvarem v porovnání s femorální a tibiální chrupavkou, což je zmiňováno autory. Není jasné, zda metoda Live Wire by pracovala identicky v případě chrupavek, zatížených degenerativními změnami, obzvláště v případech, kdy by bylo využito magnetického pole s nižší intenzitou. Nicméně tato metoda poskytuje dobrou alternativu pro manuální segmentaci s průměrným operačním časem 30 sekund na jeden řez (15 minut pro celé koleno) a přídatných 15 minut pro trénování.

Následující využitelnou alternativou je metoda graph-cut. Inicializace algoritmu je provedena umístěním několika semínkových linií uvnitř chrupavky a okolních tkání. Semínka jsou propagována do sousedních řezů, probírající každý řez po jednom voxelu dokud linie nezmizí. Graph-cut algoritmus využívá semínkovou informaci pro separaci voxelových objektů z pozadí, kde semínka působí jako pevné hranice. Objekt je segmentován na základě narušení hran grafu, takovou cestou, že cost funkce je minimalizována (rovnice 3.5). Uzly grafu jsou reprezentovány voxely a tzv. cost hrany jsou složeny z regionálních a hraničních vlastností. Regionální vlastnosti přinášejí informaci jako je pravděpodobnost, že voxel náleží do objektu, tzv. cost hranice zahrnuje informace o vnitřní voxelové vzdálenosti a diferencích jejich intenzit (rovnice 3.6).

$$E(A) = \sum_{p \in P} R_p(A_p) + \sum_{\{p,q\} \in N} B_{\{p,q\}} \quad (3.5)$$

$$B_{\{p,q\}} = \exp\left(-\frac{(I_p - I_q)^2}{2\sigma^2}\right) \cdot \frac{1}{dist(p,q)} \quad (3.6)$$


Metoda byla testována dvěma nezávislými experty s využitím obrazových záznamů osteoartritidy s variabilním stupněm stádia onemocnění, kde KL skóre je v rozpětí 0-4. Intra-observační variabilita je měřena na základě opakujících se experimentů s 4 týdenním odstupem. Inter-observační chyba v chrupavce je vyšší pro osteoartritické změny, než pro fyziologickou chrupavku. Nicméně algoritmus není validován kvůli absenci zlatého standardu. Proto je komplikované relevantně posoudit, zda proces vykazuje relevantní a přesné výsledky. Průměrný čas, potřebný pro zpracování, se pohybuje mezi 30-50 minutami pro jeden řez, což představuje pouze lehké zlepšení považované manuální segmentaci, kdy uživatel opakovaně rozmisťuje semínka. Cíl dalšího vývoje metody může být automatické rozložení semínek. Tato funkcionality by eliminovala faktor subjektivity v inicializační fázi algoritmu, což by pravděpodobně zlepšilo dosažené výsledky.

Další modalitou je využití souřadnicového systému (LCS) a rigidní objektové registrace pro hodnocení chrupavek v rámci rozsáhlých studií. Uživatel rozmisťuje semínkové linie v blízkosti chrupavky, povrch chrupavky je extrahován na základě využití aktivních kontur (snakes). Tento povrch je využit pro inicializaci segmentace na sousedící řezy.

Pro časovou komparaci chrupavek je potřeba provést vzájemnou registraci segmentace, protože pozice a orientace kolena je pravděpodobně změněna v rámci jednotlivých řezů. Autoři tvrdí, že v rozsáhlých studiích artikulační strana chrupavky prochází více změnami než strana přechodu kosti ke chrupavce, a tak je logické fixovat souřadnicový systém do BCI strany. Femorální chrupavka je transformována do cylindrických LCS a tibiální chrupavka je mapována na planárních LCS s využitím metody proložení nejmenších čtverců. Každý bod v rámci geometrického modelu je definován jako tzv. offset nejbližšího bodu kontury chrupavky. Mapa tloušťky je generována na základě výpočtu vzdálenosti mezi offsetovým bodem BCI k offsetovému bodu hrany artikulační chrupavky.

Navzdory skutečnosti, že tradiční validační přístup využívá zlatého standardu, autoři se rozhodli pro validaci algoritmu na základě syntetického MR obrazu (obrázek 36). Signálové intenzity v syntetickém obrazu jsou odvozeny z měření distribuce intenzit v kosti, synoviální tekutiny a chrupavky v rámci 100 obrazových záznamů. Obrazy jsou degradovány aditivním šumem, generovaným na základě Ricianovy pravděpodobnostní funkce. Není zcela zřetelné, zda algoritmus vykazuje relevantní odhad, jelikož využívá idealizující situaci, poskytující čistý kontrast mezi chrupavkou a obrazovým pozadím. V rámci reálných podmínek jsou kosti obklopeny ostatními tkáněmi, kromě artikulační chrupavky, jako je tuková tkáň, svaly a synoviální tekutina. Některé z těchto komponent disponují velmi špatným kontrastem vůči chrupavce, v závislosti na akvizčních obrazových parametrech.

Registrační algoritmus demonstruje dobré výsledky v rámci kontextu rozsáhlých studií. Poziční chyba je shledána signifikantně nižší, než minimální voxelová velikost (0.02 oproti 0.03 mm) a variační koeficient pro objem v syntetických MR obrazech je nízký, okolo 0.1%. [123-125]



Obrázek 36 Syntetický MR obraz kolena na základě sloučení 100 obrazů. (a) Tibiální kost a chrupavka. (b) Femorální kost a chrupavka. [126]

3.7 Plně automatická segmentace

Iniciativní projekt, zabývající se studiem osteoartritidy, nabízí mnoho obrazových dat pro výzkumné účely, nicméně poloautomatická segmentace každého řezu stále vyžaduje podstatnou supervizi, a tak se automatická segmentace stala velice aktuálním námětem v rámci recentní literatury, jelikož umožňuje segmentaci chrupavek bez jakékoliv interakce uživatele. Přístupy pro automatickou segmentaci artikulárních chrupavek zahrnují následující přístupy:

- Analýzu textur
- Neuronové sítě kNN
- Statistické modely – Active shape models, Kurhunen-Loeve expanzi s adaptivním spojováním vzorů (Template Matching)
- Graph-cuts metody


3.7.1 Analýza textur

Chrupavka je segmentována na základě klasifikace, využívající textury tkání. BCI je detekována na základě automatické metody, popsané v publikaci od autorů Lorenz a von Berg. Algoritmus pro segmentaci kostí obsahuje generátor paprsků, vzorkovač paprsků a paprskový analyzátor. Paprskový generátor je konstruován setem směrů od specifického bodu, který může být aranžován na několik cest, např. cirkulární, sférickou, paralelní. Paprskový vzorkovač čte intenzity voxelů podél paprsků, v případě nutnosti provádí vyhlazení obrazu. Paprskový analyzátor determinuje, zda je objekt zasažen na základě pohledu, zda kritéria jsou splněna. Výsledek první paprskové analýzy může být využit pro inicializaci následujícího hledání.

V případě nalezení hrubé BCI kontury, je konstruována matice intenzit BCI povrchu. Pro každý vzorkovaný bod je analyzována tkáň v okolí na základě histogramové informace. Autoři rozeznávají dvě vlastnosti tkáňových textur: jas a homogenitu (Obrázek 37). Tmavé a světlé tkáně jsou separovány na základě minimalizace variace mezi dvěma korespondujícími módy v histogramu na základě Otsu metody. Světlé regiony jsou tedy dále prahovány na základě homogenity tkání. Synoviální tekutina je eliminována z masky na základě využití faktu, že voda je více homogenní než chrupavka (DESS

obrazy), a tak Otsu metodou mohou být tyto komponenty navzájem separovány. Metoda je validována na základě výsledků poloautomatické segmentace.

	Very homogeneous	Homogeneous	Inhomogeneous
Very Bright	Water	Water Cartilage	
Bright	Water Cartilage	Cartilage	Soft tissues
Dark		Dark cartilage Cartilage lesion	Cartilage lesion



a)

b)

Obrázek 37(a) Klasifikace tkání na základě jasů a homogenity voxelů v sousedství. (b) Výsledná maska chrupavky překrytá do profilové mapy. [127]

Tato metoda se jeví jako senzitivní ke kontrastu tkání, jelikož Otsu prahování je optimální v případě čisté separace mezi dvěma módy (tmavé a světlé tkáně). Zatímco DESS sekvence poskytuje dobrý kontrast mezi chrupavkou a obrazovým pozadím, tekutina se rovněž jeví světlou reprezentací v obrazových datech. Autoři tvrdí, že tekutina je v průměru více homogenní než chrupavka. V rámci budoucího vývoje by algoritmus měl být testován na širším vzorku obrazů.

Algoritmus je validován na základě komparace výsledků segmentace s výstupem poloautomatické metody, prezentované autory Kauffmann a kolektiv, což je nevýhodou, protože manuální segmentace je stále považována jako zlatý standard v oblasti generace zlatého standardu. Kromě toho algoritmus, navrhovaný autory Kauffmann a kolektiv není manuálně validován expertní segmentací, ale pouze syntetickými MR obrazy. [128]

3.7.2 Učení s učitelem

Publikace, navržená autory Folkesson a kolektiv popisuje kNN přístup pro segmentaci chrupavek. Algoritmus je složen ze dvou rozlišných binárních klasifikátorů, využívaných separátně pro tibiální a femorální chrupavky. Klasifikátory jsou optimalizovány pro zahrnutí vlastností, které jsou typické pro každý typ chrupavky, která je segmentována. V případě tibiální chrupavky je kalkulováno s následujícími vlastnostmi: pozice v obraze, intenzity po vyhlazení obrazu s Gaussovým filtrem, kde je využíváno 3 variabilních filtračních jader, Hessian, první derivace, vlastní čísla Hessianu a vlastní čísla strukturálního tenzoru, generovaného na základě první derivace, konvulované s Gaussovým filtrem. Klasifikátor pro femorální chrupavku disponuje následujícími vlastnostmi: pozice, vektor vlastních hodnot strukturálního tenzoru, první derivace dvou rozlišných stupnic, obrazové intenzity po vyhlazení, vlastní hodnoty Hessianu a vlastní hodnoty tenzoru. Autoři tvrdí, že $k=100$ je optimální počet nejbližších sousedních parametrů, založených na empirických pozorováních. [106]

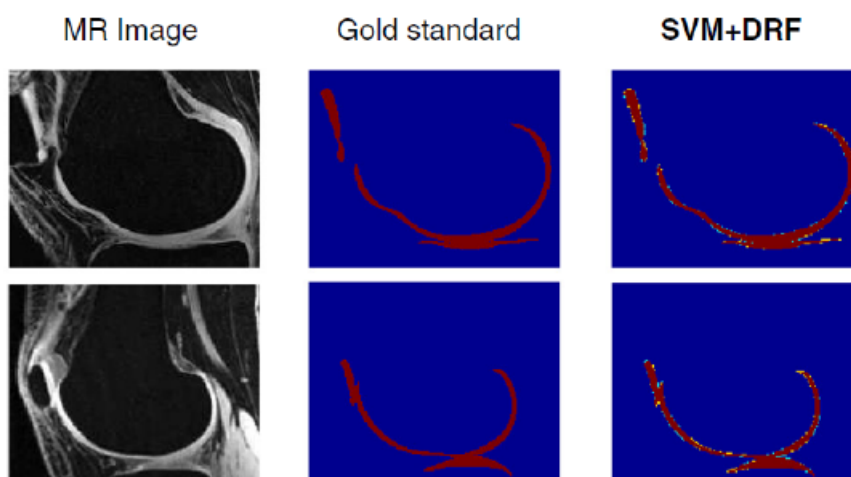
Na základě skutečnosti, že kNN klasifikátor typicky trpí nedostatkem výkonu, autoři se rozhodli pro optimalizaci algoritmu s využitím následující metody. V prvním kroku je klasifikován menší počet voxelů, lokalizovaných zhruba u středu datasetu. Jestliže je voxel přidružen k chrupavce, algoritmus postupuje k testování sousedních voxelů. Proces je opakován, dokud nejsou zbývající voxely přidružené k chrupavce. Výsledné propojené komponenty jsou slučovány, aby byla každá chrupavka dána jedním komponentem. Kvůli tomuto faktu není pozice kolena v příslušném řezu konzistentní. Po

segmentaci chrupavky je obraz posunut, aby těžiště segmentace korespondovalo s některým s trénovacích dat. Masky artikulární chrupavky je dilatována 3 voxely, následovanými kNN klasifikátorem s výsledným VoI. Senzitivita algoritmu ($DSC=0.80$) je porovnatelná s intra observační chybou ($DSC=0.87$).

V rámci budoucí práce by bylo výhodné, aby bylo k dispozici více dat zlatého standardu, alespoň dalšího experta pro testování inter observační variability.

Jednou z majoritních nevýhod je fakt, že tato metoda byla pouze testována MR 0.18T. Proto není zcela jasné, zda tato metoda bude relevantně použitelná pro běžně využívanou modalitu 1.5T, kde je vyšší rozlišení. Z hlediska počítačích náročnosti je zřejmé, že s narůstajícím rozlišením, tedy počtem pixelů, se rovněž zvyšují počítačové nároky segmentačního procesu. Tento fakt je důležitý v případě využívání kNN klasifikátorů, u kterých je dobře známo, že jsou relativně pomalé, což je rovněž zmiňováno autory. Algoritmus je pouze testován na obrazových výstupech femorálních a tibiálních chrupavek. Rovněž je zmíněno, že pozice voxelu představuje nejvíce signifikantní vlastnost jak pro tibiální, tak pro femorální chrupavku, autoři tvrdí, že jejich metoda je robustní vůči pozici kolena v rámci příslušného řezu. [106]

Zhang a kolektiv kombinují metodu Support Vector Machine (SVM) s diskriminantními náhodnými poli (DRF) pro segmentaci femorální, tibiální a patelární chrupavky na multikontrastních MR obrazech. Každý dataset obsahuje kombinaci čtyř obrazů, skenovaných následujícími sekvencemi: FS SPRG, IDEAL-GRE water, FIESTA, IDEAL-GRE fat. Důvodem pro využití multikontrastních obrazů je kombinace informací, které mohou být pouze získány ze specifických sekvencí, jako je kontrast mezi kostí a chrupavkou, kontrast mezi tkání a tekutinou, atd. SVM a DRF jsou kombinovány pro vzájemnou komplementaci. Zatímco SVM je úspěšná pro klasifikaci individuálních voxelů, ale nebere v potaz okolní voxely. DRF bere v úvahu prostorové závislosti mezi sousedními voxely, ale není vhodná pro binární klasifikaci. [129]



Obrázek 38 Komparace zlatého standardu s automatickou segmentační metodou SVM-DRF. [129]

Lokální závislost voxelů je definována mřížovým grafem s konektivitou 10 sousedů. Femorální, tibiální a patelární chrupavky jsou segmentovány nezávisle, např. femorální oproti zbytku. Algoritmus je optimalizován na základě tzv. loopy belief propagace, která bere v úvahu informaci z předešlých pozorovaných módů. Jeden vzorek je nabrán jako testovací data, zbytek je využit pro trénovací data.

Následující vektory jsou vybrány pro metodu SVM, založenou na tzv. highest observed Dice coefficient: 4D normalizované intenzitní hodnoty multikontrastního MR, lokální struktura obrazu, založená na vlastnostech (zahrnující gradient vyhlazeného obrazu Gaussovským filtrem, vlastní hodnoty Hessianu) a 3D geometrické vlastnosti. Další jsou získány na základě extra segmentačního kroku kostí, založeného na prahování, následovanou metodou component labeling. A tak každý voxel je reprezentován 31-D vektorem.

Validace algoritmu je provedena s využitím manuální segmentace, provedenou klinickým expertem. Výsledná segmentace je rovněž komparována s výstupem ostatních metod, prezentovaných v literatuře, zahrnujících kNN klasifikátor, navržený autory Folkesson a kolektiv, deformovatelnými modely od autorů Fripp a kolektiv a graph-cuts metodou od autorů Lee a kolektiv. Autoři tvrdí, že jejich metoda produkuje většinu přesných výsledků oproti uvedeným metodám. Autoři současně zmiňují, že metoda využívá multikontrastní informace analyzovaných dat. Stále není zřetelné, zda metoda je kvalitnější oproti klinickému testování, kde dostupnost multikontrastních dat je limitována. Rovněž není provedeno testování, které by dokládalo přesnost výsledků v oblasti patologických oblastí. Výsledky indikují, že reprezentace geometrických vlastností má signifikantní dopad na přesnost, proto by měla být věnována pozornost segmentačnímu kroku kostních struktur v rámci budoucího vývoje. [129, 130]

3.7.3 Statistické modely

Angelini a kolektiv přistupovali k úloze ve dvou krocích. V prvním kroku jsou využita data pro genezi VoI atlasu chrupavky s manuálním vyprázdněním hranic chrupavky. Ve druhém kroku je atlas mapován takovým způsobem, že minimalizuje variaci intenzity u korespondujících voxelů. Autoři využívají diskrétní verzi analýzy nezávislých komponent, nazývanou Karhunen-Loeve expanze. [131]

V prvním kroku jsou obrazové záznamy normalizovány na základě nulové střední energie. Střední obraz je odečten od každého konkrétního objektu a dělen normalizovanou střední energií. Poté pro každý obraz je manuálně načrtnuto rozhraní chrupavky expertem. Oblast zájmu je konstruována na základě vzorkování všech voxelů v průběhu 2.5mm a to od nejbližšího hraničního bodu artikulární chrupavky. Oblasti zájmu jsou následně vzájemně registrovány s využitím adaptivního spojování vzorů (Template Matching), což je obdobný postup jako afinní registrace. Stupně volnosti zahrnují translaci, rotaci a stupňování. Od tohoto bodu může na každé transformované RoI být nahlíženo jako na multidimenzionální vektor, kde každá osa koresponduje s pozicí voxelu v rastrovém pořadí (svrchu dolů a zleva doprava). Za předpokladu minimálních anatomických variací mezi jednotlivými pacienty, voxelové intenzity by měly vykazovat normální (Gaussovo) rozložení. Následující vztah popisuje kovarianční matici, kde A je kovarianční matice, e je vlastní vektor a λ představuje vlastní čísla. [131]

$$A_{e_k} = \lambda_k e_k, k = 1, \dots, n \quad (3.7)$$


Tento přístup je nazýván Karhunen Loeve expanze. Pro formování prototypického RoI autoři využívají 3 největší vlastní čísla a kalkulují váženou sumu jejich korespondujících vektorů vlastních čísel, aby bylo možno formovat obraz. [131]

Aby bylo možné seřadit rekonstruované RoI s testovacími obrazy, prototyp je konvolován napříč všemi možnými startovacími pozicemi a na základě dvou podobných metrik je nalezena optimální lokace: křížová korelace a SSD (součet čtvercových diferencí). Nejlepší pozice prototypu by

byla v bodu, kde křížová korelace dosahuje maxima, a zároveň SSD je minimální. Tyto body se nutně neshodují, a tak váha je přiřazena ke každé metrice, závisující na lokálním gradientu podél mřížky. Proces je zastaven, když obě metriky dosahují podobného extrému. Jakmile je optimalizována lokace prototypu, hranice chrupavky mohou být nalezeny při pohledu na gradient podél normál k prototypickým hranám RoI. K fitování nejstrmějšího gradientu je použita křivka 2D spline. [131]

Výsledek je validován na základě výpočtu Euklidovy vzdálenosti mezi zlatým standardem a výslednou křivkou. Ačkoliv chyby (0.62mm, 0.3mm a 0.42mm pro femur tibiai a chrupavku) jsou menší než velikost voxelu (0.47mm), musíme brát v úvahu fakt, že obrazy jsou interpolovány, což přispívá k výsledné chybě. Tato metoda je celkově spjata s několika limitacemi. [131]

Nevýhodou Karhunen Loeve expanze je fakt, že vyžaduje, aby distribuce vykazovala normální rozložení, což je spjata s požadavkem velkého množství dat. Autoři korektně poukazují, že je potřebné využít větší počet datových souborů pro zkoumání inter anatomických diferencí, s cílem následného dosažení normálního rozložení. Pokud bychom chtěli navíc zvětšit obrazové rozlišení, počet voxelů v RoI by rovněž vzrostl a to na základě výrazu n^3 , kde n , představuje počet dimenzí. Tento jev by měl drastický efekt z hlediska výpočetního času. Autoři neudávají žádný konkrétní údaj ohledně výpočetní náročnosti řešení. Výpočetní čas je určen na základě velikosti obrazu (počet startovacích lokací) a jak rychle RoI konverguje ke globálnímu extrému. [131]



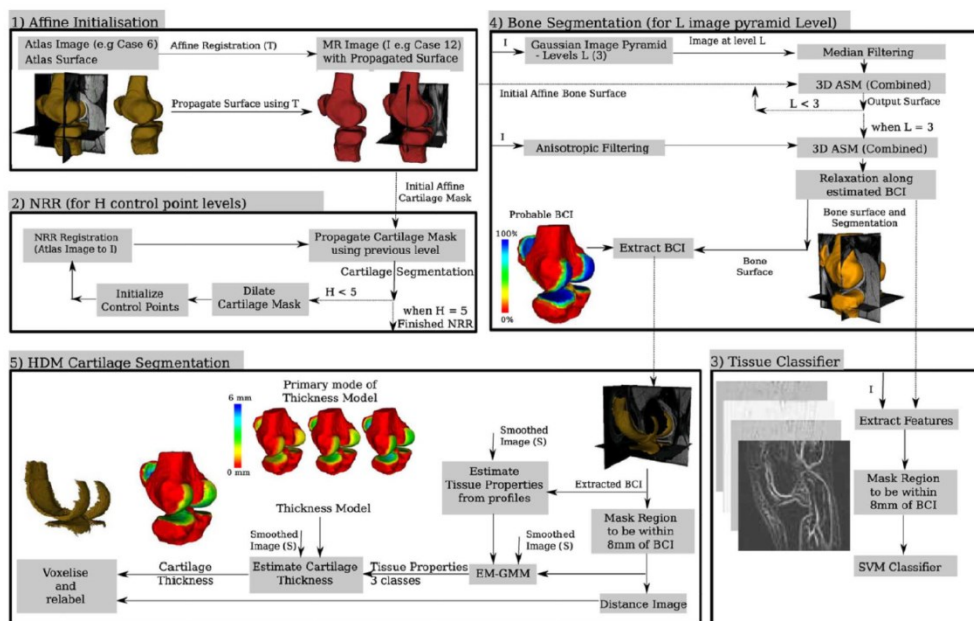
Obrázek 39 (a) Lokace prototypové masky po adaptivní translaci. (b) Koincidence zlatého standardu a segmentace. [131]

Dalším ze statistických metod je hierarchický přístup, prezentovaný autory Fripp a kolektiv. V rámci této metody je hledáno rozhraní mezi kostí a chrupavkou, jelikož tato lokace udává spolehlivou inicializaci pro detekci chrupavky. V prvním kroku je konstruován statistical shape model (SSM) kostí. Kostí jsou parametrizovány na základě mapování povrchu sféry, která obklopuje objekt na povrchu objektu, narušující mřížku, v případě potřeby detailů. Kostí v testovacích datech jsou segmentovány s využitím tzv. 3D active shape models. [106]

Po inicializaci je model iterativně deformován podél normál k povrchu a tvar je omezen statistickými omezeními. Inicializace je provedena na základě afinní transformace atlasu s korespondujícím modelem kosti k testovacímu obrazu. Hranice jsou určeny cestou podél normál k povrchu a nalezení nejsilnějšího gradientu podél profilu. [106]

BCI je segmentována s využitím active shape model, aplikovaném na celém kolenu s 3 stupňovou tzv. multi-resolution Gaussian pyramid, kde analyzovaný obraz je vyhlazen mediánovým filtrem a převzorkován lineární interpolací. Inicializační odhad kostní tkáně je proveden na základě Otsu

metody prahování, autoři poukazují, že tato metoda není optimální, ale postačující pro inicializaci. Vlastnosti tkání jsou odhadovány na základě Gaussovy distribuce intenzit ve vzorku. [106]



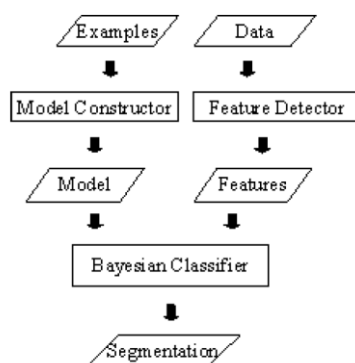
Obrázek 40 Automatické rozhraní extrakce kost-tkání, následované segmentací chrupavky. [130, 132]

Voxely chrupavky jsou klasifikovány s využitím maximalizace tzv. Gaussian mixture model. V prvním kroku je generována binární maska, pokrývající voxely v průběhu 8mm z BCI. Algoritmus hledá největší gradient podél normál k masce a bere v úvahu statistická data z trénovacího setu. Tvarová omezení jsou rovněž zesílena využitím BCI informace. Proces je několikrát opakován, aby bylo redukováno vyhledávané rozpětí v každé iteraci, dokud není dosaženo konvergence. Jakékoliv překryté voxely jsou separovány s využitím distančních polí. [106]

Validace algoritmu je provedena expertní manuální segmentací (DSC=0.803 a 0.77 pro femorální, respektive tibiální chrupavku) a porovnáním s výsledky segmentačních algoritmů, prezentovaných autory Folkesson a kolektiv, Grau a kolektiv a Glocker a kolektiv. DSC je horší než u metody Watershed, ale je porovnatelná s ostatními dvěma metodami. Jak autoři zmiňují v diskuzi, algoritmus je senzitivní k segmentaci kostí, neúspěšnost algoritmu je registrována pro segmentační případy chrupavek 3.6%. Z tohoto důvodu by měla být směřována pozornost ke kroku extrakce BCI v rámci budoucího vývoje. Algoritmus je rovněž senzitivní k prezenci šumu a parciálnímu objemovému efektu, což je zmiňováno autory v textu. Jelikož je algoritmus pouze testován na fyziologické chrupavce, tento nedostatek by mohl být umocněn v případě testování na degenerovaných chrupavkách. Výpočetní čas celého procesu je přibližně 20-25 minut, což představuje slušný výkon v rámci faktu, když bereme v úvahu vysokou přesnost výsledků bez jakékoliv interakce uživatele. [106, 117]

3.7.3.1 Praviděpodobnostní segmentační model

Praviděpodobnostní model popisující prostorové vztahy mezi vlastnostmi artikulární chrupavky je konstruován na základě 3D manuálně segmentovaných dat. Ve spojení s algoritmem feature detection je tento model využit pro segmentaci kolenních řezů. V první rozsáhlé fázi segmentace je řešena segmentace lehce získatelných struktur, aby byla následně využita pro navedení konsekventní segmentace dalších struktur. Sekvenční přístup umožňuje využít specifický algoritmus, aplikovaný na specifické anatomické struktury v každé nové fázi metody. Například je započato s automatickou segmentací femuru, tímto se získá prostorová omezení sousedních struktur, jako je femorální chrupavka. Navíc segmentace rozsáhlých struktur začíná procesem možnosti kalibrace tzv. získového pole a aplikováním korekcí pixelových intenzit před pokračováním procesu segmentace. Inicializační práce tohoto přístupu pohlíží na segmentaci pouze 4 struktur: femur, femorální chrupavka, tibia a tibiální chrupavka. [133, 134]



Obrázek 41 Vývojový diagram segmentačního modelu kolena. [134]

Segmentace femuru a tibie představuje dvoufázový proces, využívající interaktivní vstup pro získání tzv. seed regionů. V prvním kroku je řešen tzv. adaptivní region growing, analyzující lokální texturové vlastnosti každého seed regionu a využívající kritérií homogenity pro evoluci křivky kosti. S rostoucím regionem jsou simultánně aktualizovány statistiky lokálních textur, což předurčuje adaptivnost procesu. Abychom se vyhnuli štěrbinám v jednotlivých texturách pro spojené hranové kontury, jsou využita heterogenní kritéria. Ve druhém kroku jsou lokalizovány hranice kostí na základě využití tzv. snake-like regularizátoru. Následující výstup ukazuje tzv. seed region na klinickém MRI řezu, výsledek adaptivní metody region growing a výsledek, regularizující hranice. [133, 134]



Obrázek 42 Klinický MRI řez podél seed regionu, který je interaktivně získán (vlevo). Výsledek adaptivní metody region growing s využitím semínek (uprostřed). Výsledek metody snake-like regularizer, získaný metodou region growing (vpravo). [134]

Navrhovaný detektor příznaků hledá hranice měkkých kostí. V rámci klinických řezů, jako je uvedený výstup, je kontrast mezi kortikální kostí, chrupavkou a vazy relativně slabý. Proto je obtížné provést diferenciaci mezi kortikální kostí a chrupavkou.

Segmentace tibiální a femorální chrupavky je řešena ve dvou krocích. Prvním krokem je modelování prostorových vztahů. Zde je využit model, kódující prostorové vztahy mezi femurem, femorální chrupavkou, tibií a tibiální chrupavkou. V rámci tohoto kroku jsou pozorovány prostorové vztahy mezi femurem a femorální chrupavkou. Tyto závislosti jsou popsány na základě vzdálenosti mezi chrupavkou a povrchem femuru, také lokální orientací femuru, kde je chrupavka přidružená. Vztah mezi femorální chrupavkou a femurem je popsán třídí podmiňovací pravděpodobnostní funkcí hustoty pravděpodobnosti. Tato funkce je konstruována z příkladů, kdy chrupavka a femur jsou manuálně popsány experty. Je důležité poznamenat, že tento model představuje kombinaci heuristiky a trénování na základě příkladů. Autoři tvrdí, že informačně teoretická schémata mohou být rovněž navržena pro automatické odvozování vztahů z příkladů.


Druhým krokem je Bayesova klasifikace. Tento krok využívá model a vlastnosti (F , T), které již byly popsány pro identifikování chrupavky. F označuje set voxelů, náležících oblasti femuru. Tato procedura je složena ze dvou kroků:

Interferenční krok: Výpočet pravděpodobnosti, že lokace voxelu by měla být klasifikována jako femorální chrupavka na základě pozorování intenzity a prostorových relací k femuru.

Rozhodovací krok: Klasifikace každého voxelu chrupavky s využitím pravděpodobností, kalkulovaných v interferenčním kroku.

Rozhodovací fáze aktuálně prahuje pravděpodobnosti na základě využití hystereze, aby bylo rozhodnuto mezi oblastmi, které korespondují s chrupavkou a okolím.


Autoři v rámci studie navrhnou databázi MR kolenních obrazů, disponujících vysokým rozlišením, které jsou manuálně segmentovány. Prezentované výsledky byly získány z řezů velikosti 512x512x87 voxelů a rozlišení 0.25x0.25x1.4 mm. V rámci vyhodnocení výsledků je využito manuálně segmentačních modelů femuru a tibie pro trénování navrženého systému. Autoři prezentovali výsledky na třech variabilních MR řezech, které jsou použity v rámci trénovacího procesu. Rovněž autoři v rámci studie komparují dosažené výsledky v konfrontaci s manuální segmentací. Nicméně je zjevné, že navržená metoda vykazuje jisté slabiny. Optimální kvantování může vyžadovat více trénovacích dat, aby bylo možné odhadnout kloubní hustotu. V rámci budoucího výzkumu by problematika měla být směřována na genezi modelů svalů, vazů a menisků, kromě již existujícího modelu chrupavky. [133, 134]



Obrázek 43 Výstupy segmentace chrupavky na základě pravděpodobnostního segmentačního modelu. [134]

3.7.4 Segmentace na základě Houghovy transformace a adaptivní Cannyho detekce

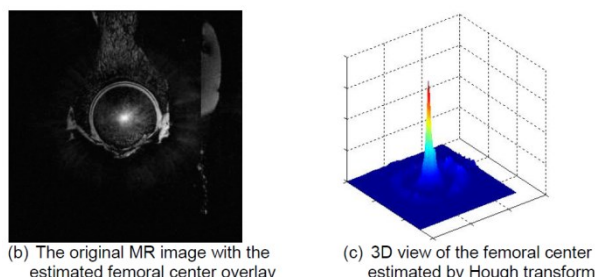
V rámci této studie je navržena metoda automatické segmentace, založená na Houghově transformaci a detekci hran s cílem separace femorální chrupavky kyčelního kloubu z MR obrazů. První částí navrženého řešení je předzpracování obrazových MR záznamů. MR obrazy jsou získány z pravé strany kyčelní pánve dospělého muže (35 let) s využitím tzv. Fast spoiled gradient-echo sekvence, aby bylo možné provést projekci obrazu do sagitálního směru. Konkrétně je využita MR modalita 1.5T HDe od firmy GE. Samotné předzpracování obrazu zahrnuje interpolaci, vyhlazení a vylepšení jasových vlastností obrazu. Interpolace je využita z důvodu optimalizace přesnosti efektu segmentační procedury. Tato procedura vylepšuje rozlišení z 256x256 pixelů na 512x512 pixelů. Vyhlazení obrazu je vykonáno na základě interpolační procedury a základě Gaussovy filtrace s cílem redukce obrazového šumu. Aby bylo možné vylepšit kontrast artikulární chrupavky od obrazového pozadí, je využito tzv. Fuzzy enhancement metody. [134]



Obrázek 44 Komparace originálního záznamu (vlevo) a optimalizovaného záznamu (vpravo). [134]

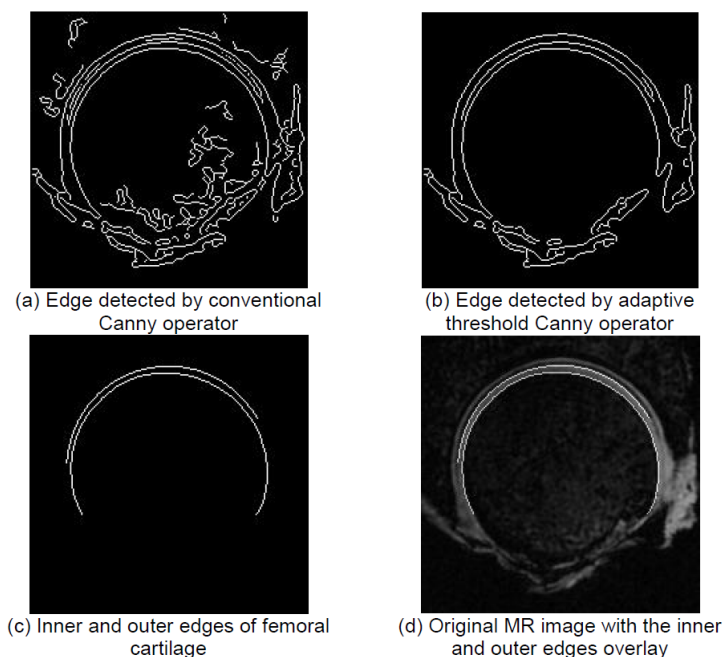
Považujeme-li metodu hranové detekce za senzitivní vůči šumu, je v prvním kroku segmentace extrahován hrubý region, aby bylo konsekventně možné redukovat šum. Autoři předpokládají, že femorální chrupavka disponuje specifickou sférickou strukturou. Aby bylo možné automaticky selektovat cílovou oblast zájmu, je využito Houghovy transformace pro detekci centru femorální hlavy v MR řezu, zjištěním středu sféry. Chrupavka poblíž hranových pixelů disponuje následujícími

charakteristikami: (1) gradientní vektor pixelu je aranžován podél směru ze středu k pixelu, (2) modul gradientního vektoru je značně velký. Dle uvedených charakteristik může být kalkulována adaptivní prahovací podmínka gradientního vektoru. Největší element poté představuje středovou pozici femorální hlavy. [135]



Obrázek 45 Nativní MR obraz s odhadovaným femorálním centrem (b) a 3D pohled na femorální centrum na základě Houghovy transformace (c). [135]

Aby bylo dosaženo přesné segmentace femorální chrupavky, hrany chrupavky musí být přesně extrahovány. Adaptivní prahovací Cannyho hranový operátor je v rámci tohoto kroku implementován s cílem detekce hran v cílové oblasti. Cannyho operátor vyžaduje nastavení dvou prahů pro dosažení hranové detekce. K realizaci nemanuální intervence adaptivního dynamického prahování je implementována selekční prahovací metoda. Velkou výhodou je, že proces nevyžaduje jakoukoliv manuální intervenci. [135]



Obrázek 46 Detekce hran femorální chrupavky a potlačení šumu. [135]


V rámci testování segmentační procedury na nativních MR datech autoři tvrdí, že z celkového vzorku 120 obrazových záznamů, je metoda úspěšná na 117 záznamech, tudíž míra úspěšnosti řešení je víc než 97%. Zároveň autoři uvádějí, že důvod neúspěchu metody na ostatních záznamech je způsoben faktem, že femorální chrupavka není dostatečně fokusována, což může zapříčinit její

nežřetelnost a tudíž předpoklad nekorektní segmentace. Autoři rovněž uvádějí, že případy úspěšné segmentace jsou komparovány s výsledky manuální segmentace a výsledky vykazují průměrnou úspěšnost mezi těmito dvěma metodami 95.3%. [135]

3.7.5 Segmentace na základě rozpoznávání vzorů

Metoda využívá tři binárních klasifikátorů s integrálními a parciálními vlastnostmi pixelů na základě Bayesova teorému s primárním cílem separátní segmentace femorální chrupavky, tibiální chrupavky a patelární chrupavky. V rámci studie byla zpracovávána MR data, poskytnutá oddělením radiologie Southwest Hospital, Third Military Medical University. Data zahrnují sagitální MRI obrazy pravého kolenního kloubu šesti zdravých dobrovolníků s průměrným věkem 23 let. Data jsou získána z MR 1.5T SIEMENS, konkrétně bylo využito T2 vážených sekvencí a sekvencí s potlačením tuku.

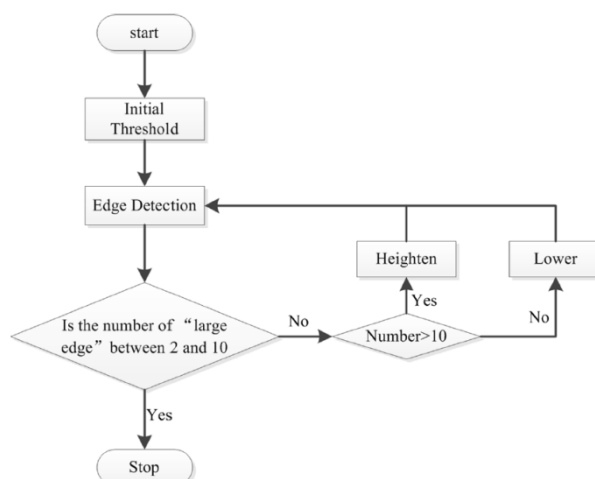
BCI (zahrnující hrany kostí) je jednoduché identifikovat a zároveň jsou nápomocné pro určení pozice chrupavky. BCI je získáno v prvním kroku, a poté je segmentována artikulární chrupavka. Následující výstup popisuje průběh segmentační procedury. [136, 137]



Obrázek 47 Blokový diagram segmentační metody, využívající rozpoznávání vzorů. [136]

V prvním kroku jsou detekovány silné hrany na základě Cannyho operátoru a konsekvntně je získáno BCI. Následně je přistoupeno ke klasifikaci pixelových vlastností (vzdálenost od BCI a intenzita) a rovněž je kalkulována variance intenzit osmi sousedních pixelů v rámci předzpracovaných obrazů. V předposledním kroku je využito Bayesova klasifikátoru s cílem pixelové klasifikace s využitím vzdálenosti od BCI, pozice, intensity a variance. Ve finálním kroku jsou získány segmentační výstupy. [136, 137]

Hlavní detekovatelné hrany představují femur, tibia, patelu a svalovou tkáň. Tyto hrany disponují vysokou úrovní gradientu. Nicméně autoři uvádějí, že tato hranová detekce není úspěšná v rámci všech MR řezů, z čehož logicky vyplývá, že úspěšnost detekce chrupavky by nebyla spolehlivá. Z tohoto důvodu je v rámci metody řešena tzv. optimalizace hran. Ostatní hrany jsou rovněž detekovány na základě adaptivního prahování, např. se jedná o svalovou tkáň a kompaktní kosti. U některých případech jsou hrany narušené, tudíž nejsou souvislé, nebo jsou zdvojené. Proto je metodika doplněna o morfologické zpracování, aby bylo dosaženo přesnějších výsledků. [136, 137]



Obrázek 48 Vývojový diagram detekce hran, založený na iterativním prahování. [136]

Klíčovým komponentem metody je extrakce vlastností. K tomuto účelu je využito následujících vlastností: intenzita, vzdálenost od BCI, gradientní norma, určená Prewitovým operátorem, a pozice. Všechny uvedené vlastnosti jsou kalkulovány po vyhlazení obrazu Gaussovým dolnopropustným filtrem. Vzdálenost je kalkulována na základě Euklidovy vzdálenosti mezi každým pixelem a korespondujícím nejbližším bodem BCI. V případě, kdy je pixel lokalizován uvnitř kostní tkáně, vzdálenost je považována za negativní. Vzdálenost z BCI a pozice může limitovat rozsah klasifikace pixelů a je rovněž užitečná pro rozpoznání chrupavky od svalové tkáně, která je lokalizovaná poblíž chrupavky. [136, 137]

Autoři uvádějí, že pro vykonání automatické segmentace je vyžadováno 10 minut výpočetního času, což zahrnuje 30-42 minut výpočetního času pro jeden případ. Autoři rovněž uvádějí, že hrany segmentované chrupavky jsou vyhlazeny a kontaktní chrupavka je úspěšně segmentována, což je hodnoceno kvalitativní analýzou. Aby bylo možné provést kvantitativní komparaci mezi manuální a automatickou segmentací, je kalkulován parametr *DSC*, což představuje zlatý standard pro hodnocení segmentačních výsledků. Parametr *DSC* je kalkulován následujícím způsobem:

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|} \quad (3.8)$$

Kde *X* představuje manuální segmentaci a *Y* automatickou segmentaci. Autoři uvádějí, že hodnoty parametru *DSC* těchto typů chrupavky jsou větší než 0.7 (průměrně 0.761), což indikuje dobrou shodu mezi výsledky získanými prezentovanou metodou a manuální segmentací. [136, 137]

4 Modelování morfologické struktury artikulárních chrupavek

Jak již bylo zmíněno v předešlých kapitolách, pro vizualizaci kolenních chrupavek se konvenčně klinicky využívají dvě modalita, a sice ultrazvukové zobrazování a zobrazování magnetickou rezonancí (MRI). V rámci klinické diagnostiky se ve většině případů přistupuje k využití MRI, protože tato metoda generuje obrazová data ve vysokém rozlišení a se značně větším kontrastem, než je tomu u ultrazvukového zobrazování. Hlavním záměrem práce je segmentace a konsekventní matematické modelování artikulárních chrupavek na základě reálných obrazových záznamů z MR z variabilních MR sekvencí, aby mohla být deklarována robustnost metody skrze variabilní obrazové výstupy. Přes nesporné klady MR tato metoda disponuje jistými limitacemi, zejména obtížnější identifikovatelností drobných patologických změn, které jsou běžně doprovázeny slabým kontrastem oproti okolní tkáni, což je rovněž případ u prezence raných stádií degenerativních změn kolenních chrupavek. Tyto změny jsou v některých případech téměř nepozorovatelné. Značnou nevýhodou MR zobrazování je rovněž nemožnost zpracování záznamů s cílem extrakce geometrických informací.

Práce si klade za cíl genezi matematického modelu kolenních chrupavek, který je určen k precizní extrakci oblasti chrupavky s cílem identifikace oblastí, které nevykazují patologické známky vůči oblastem, kde se předpokládají patologické interrupce morfologické struktury chrupavky. Nutno podotknout, že nativní obrazová data kolenních chrupavek jsou generována v monochromatickém formátu, kde jednotlivé tkáňové struktury jsou diferencovány v odstínech šedi. Matematický model kolenních chrupavek rovněž tento fenomén kompenzuje, neboť jednotlivé klasifikační třídy, které korespondují s fyziologickým stavem chrupavčité tkáně, jsou diferencovány v barevném spektru na základě arteficiální barevné mapy. Stežejní limitací u zobrazování kolenních chrupavek je rovněž oblast jejich manifestace. Pro investigaci chrupavek je zobrazována kolenní oblast, ve které chrupavka zaujímá jen zlomek z obrazového prostoru. Z tohoto důvodu je výhodné, aby bylo přistoupeno k selekci oblasti zájmu (RoI), které umožňují fokusaci na oblast příslušné artikulární chrupavky.

Kolenní chrupavka, která vykazuje fyziologický stav, je standardně manifestována v oblasti sytě bílého monochromatického spektra. V případě prezence degenerativních změn obvykle dochází k více či méně pozorovatelné změně jasové funkce, která indikuje lokace možných patologických nálezů. Z numerického pohledu je chrupavka manifestována v jistém rozmezí hodnot jasové stupnice, avšak toto rozmezí není dáno uniformně pro libovolný obrazový záznam. Tento nepříznivý fakt vede ke skutečnosti, že není možné aplikovat jednotný pevně nastavený práh, který by diferencoval oblast chrupavky. Navíc se ukazuje, že pevně nastavené prahování obrazu je nemožné použít v oblasti identifikace drobných změn jasové stupnice. Navíc se ukazuje, že pouze jasová klasifikace může být značně neefektivní, zejména při prezenci obrazového šumu, který by pravděpodobně byl klasifikován do jiné segmentační třídy, a tak tímto způsobem by v segmentačním modelu vznikala prázdná místa, způsobená extrakcí šumových pixelů, které lokalizačně náleží do oblasti zájmu. Z toho důvodu je důležité zvážit prostorovou klasifikaci, beroucí v úvahu prostorové relace sousedících pixelů. [A.4, A.6, A.17]

Prahování obrazu představuje běžný přístup pro segmentaci obrazu s cílem extrakce jednotlivých obrazových regionů, v tomto případě mluvíme o multiregionální segmentaci. V základní formulaci prahovací algoritmus hledá globální hodnotu, která maximalizuje separaci mezi výstupními segmentačními třídami. Využití pevně nastavené prahovací hodnoty představuje zdroj významné chyby segmentace v mnoha případech, například při zpracovávání obrazových signálů, které jsou

zaneseny šumovou složkou, nebo v případech, kdy jsou objekty nerovnoměrně osvětleny. V případě objektů, které disponují nespojitými hranicemi, segmentační metody s pevně nastaveným prahováním jsou náchylné ke generování izolovaných pixelů, což je z hlediska segmentačních metod považováno jako artefakt, který znehodnocuje kvalitu segmentačního procesu.

Modelování kolenních chrupavek se opírá o design a realizaci multiregionální soft prahovací metody řízenou genetickým algoritmem, která má ambice překonat běžné nedostatky konvenčně používaných prahovacích metod v případech, kdy analyzovaná obrazová data jsou zanesena artefakty, šumem, nebo pozorované objekty jsou slabě diferencovány od obrazového pozadí. Metoda je založena na faktu, že každý obrazový bod (pixel) náleží do odlišného výstupního těžiště na základě klasifikace s využitím fuzzy membership funkce. Tímto se vyhýbáme používání pevně stanoveného rozhodovacího kritéria, které je zejména v oblasti segmentace medicínských obrazových dat obtížně aplikovatelné, neboť v mnoha případech jsou v oblasti našeho zájmu jen drobné strukturální změny, které jsou konvenčními segmentačními metodami neidentifikovatelné. Inicializační fází metody je definice výstupních těžišť na základě využití kombinovaného přístupu zahrnující klastrovací metody, která je kompatibilní s většinou prahovacích technik, které jsou uváděny v literatuře. Speciálním případem těžiště je segmentační třída, reprezentující fyziologickou chrupavku, pro kterou je použit mediánový odhad referenčního modelu. Tato inicializační těžiště jsou používána jako vstup pro genetický algoritmus, vyhledávající ideální kombinaci těžišť pro jasovou klasifikaci s cílem co nejrelevantnější aproximace struktury artikulární chrupavky a přidružených patologických nálezů, jejíž jasová spektra jsou v sousedství. Pro relevantní aproximaci artikulární chrupavky je využívána extrakce příznaků oblasti chrupavky, které definují její strukturu. Tyto příznaky jsou konsekvtně využívány pro design fitness funkce ohodnocující jednotlivá řešení evolučního procesu genetického algoritmu. V druhém kroku metoda využívá prostorovou informaci skrze lokální agregační krok, kde stupeň členství každého pixelu je modifikován lokální informací, která bere do úvahy členství okolních pixelů. Tato vlastnost dělá metodu robustní vůči šumu a artefaktům. [A.14]


4.1 Multiregionální fuzzy prahování

4.1.1 Motivace a účel

Hlavní limitací globálního prahování je fakt, že pixely, které disponují stejnou jasovou úrovní, jsou vždy segmentovány do stejné klasifikační třídy. Tento fakt může vést ke špatné klasifikaci v obrazových datech, která jsou zanesena šumem, nebo nerovnoměrným osvětlením. Tento problém lze překonat na základě zvážení prostorové informace o chování okolí každého pixelu. Tato prostorová informace může být zohledněna s využitím různých metod, každá z nich generuje rozdílný výstup segmentace. Mnoho využívaných segmentačních metod, které se souhrnně označují jako 'blind methods', čistí segmentovaný obraz s využitím lokálního zpracování, ale bez předešlé informace o obrazové struktuře rozložení obrazových objektů, původu šumových složek, atd. Zmiňované metody pouze využívají segmentované hodnoty. Typickým příkladem může být např. mediánová filtrace a morfologické operace, které jsou určeny pro odstranění izolovaných pixelů.

Využití lokální informace je demonstrováno na obrázku 49. Pixel je klasifikován jako náležící do klasifikační třídy 3, která je indikována červenou barvou. V sousedství 3x3 okolo pixelu je možné ověřit, že tento pixel představuje izolovanou hodnotu, pravděpodobně generovanou obrazovým šumem. Korekce této špatné klasifikace může být provedena s využitím informace o obrazu (jako je šumový model, pravděpodobnost klasifikace, vzdálenost k těžišti), nebo pouze využití prostorové, nebo morfologické operace. V případě provedení mediánové filtrace, která je aplikována na toto pixelové okolí, pixel bude klasifikován jako klasifikační třída 1, která je indikována modrou barvou. Podobného výsledku může být dosaženo s využitím morfologické dilatace. V těchto případech důležitá obrazová informace chybí. Z obrázku 49 je patrné, že červeně označený pixel pravděpodobně náleží do klasifikační třídy 1, a je nepravděpodobné, že náleží do třídy 2. V následující analýze bude využito tohoto faktu, aby byly brány v úvahu lokální vlastnosti klasifikovaných pixelů pro optimalizaci klasifikační metodologie.

Navrhovaná segmentační prahovací metoda generuje segmentační multiregionální model na základě separace jednotlivých rozeznatelných obrazových oblastí. Metoda následuje klasifikační přiřazení na základě fuzzy přístupu a zároveň je doplněna o prostorový agregační krok, který využívá tzv. 'soft klasifikaci' a prostorové relace. Metoda fuzzy prahování přiřazuje stupeň členství každému pixelu pro každou výstupní třídu, namísto využití konvenčně používaného pevného stanoveného prahování. Stupeň členství každého pixelu je následně modifikován využitím lokální informace, která následuje nějaké agregační schéma a případně nějakou předně stanovenou množinu fuzzy pravidel. Zařazení tohoto agregačního kroku představuje značný benefit obzvláště v případech, kde pracujeme s daty zanesenými šumovou složkou. Agregační krok by teoreticky mohl být pominut, nicméně tento finální krok klasifikační procedury zajišťuje robustnost klasifikace, zejména pro případy, kdy bereme v úvahu prezenci aditivních šumových signálů, neboť výstup klasifikace není pouze určen stupněm členství příslušného pixelu v příslušném regionu, nýbrž je zvažena prostorová informace v okolí pixelu. Jinými slovy, stupeň členství každého pixelu je modifikován dle prostorové informace. Značnou výhodou této funkcionality je fakt, že agregát nepracuje v prostoru obrazových signálů, nýbrž v prostoru fuzzy členských funkcí. [A.2, A.3, A.14]



Obrázek 49 Příklad klasifikace šumové složky na základě pevného prahování. [138]


4.2 Předzpracování MR obrazových dat

Předzpracování obrazových dat je běžně využívanou procedurou, která slouží pro optimalizaci kvality a pozorovatelnosti struktur z obrazových záznamů. Nicméně metody předzpracování obrazu mění charakter a strukturu obrazových záznamů a následně tento fakt může vést ke zkrácení informací, které jsou v popředí našeho zájmu. Navíc různorodé MR zobrazovací modalities, využívající variabilní sekvence k obrazové genezi kolenních chrupavek, disponují odlišným kontrastem a rozlišením, tudíž by nebylo možné použít unifikovanou formu předzpracování obrazových MR dat. Navrhovaná metodologie si klade za cíl, aby krok předzpracování obrazu mohl být pominut s výjimkou interpolace obrazu. Tato procedura je v rámci metodologie přínosná, neboť v rámci geneze modelu chrupavky pracujeme pouze s omezenou částí obrazového záznamu. Pro zobrazování kolenních chrupavek je typicky snímána celá kolenní oblast. Problémem je fakt, že chrupavka zabírá pouze malou plochu z celkově generovaného obrazového záznamu. Z tohoto důvodu je specifikována oblast zájmu (RoI), která fokusuje oblast chrupavky, aby byla lépe zobrazena a případné patologické změny byly lépe patrné. S fokusací obrazu je spjat fenomén, týkající se nižšího počtu pixelů, které jsou expandovány na větší obrazovou plochu. Výsledkem je skutečnost, že fokusovaná oblast disponuje relativně nízkým rozlišením, s čímž souvisí nižší kontrast, neostrost obrazové mapy a celkové zhoršení kvality obrazových informací. Tento nepříznivý fenomén může být alespoň částečně kompenzován interpolací obrazové mapy, která zvyšuje rozlišení obrazu. V rámci metodologie je aplikována v kroku předzpracování obrazu kubická interpolace, optimalizující rozlišení a pozorovatelnost obrazové mapy RoI.


V rámci testování algoritmu na reálných datech jsou v této sekci uvedeny obrazové výstupy kolenní oblasti, obsahující kolenní chrupavky. Obrazová data jsou generována MR 3T s použitou PD sekvencí (Obr. 50). V rámci testování je kolenní chrupavka fokusována s cílem maximalizace její oblasti. Algoritmus je testován pro kubickou interpolaci 2, 3 a 4 řádu (Obr. 52-54).




Obrázek 50 Originální obrazová data z MR 3T, PD sekvence kolenní oblasti s obrazovým rozlišením 512x512 pixelů. Zdroj: vlastní




Obrázek 51 Fokusovaná oblast zájmu (RoI) nativních snímků kolenní chrupavky 74x183 pixelů.
Zdroj: vlastní



Obrázek 52 RoI s aplikovanou kubickou interpolací druhého řádu. Zdroj: vlastní



Obrázek 53 RoI s aplikovanou kubickou interpolací třetího řádu. Zdroj: vlastní



Obrázek 54 RoI s aplikovanou kubickou interpolací čtvrtého řádu. Zdroj: vlastní

4.3 Segmentační algoritmus využívající soft prahování

Úvahy vycházejí z matematického aparátu, který popisuje model monochromatického obrazového signálu jakožto reálnou funkci dvou reálných proměnných $I(x, y)$, kde parametry x a y korespondují s horizontální, respektive vertikální souřadnicí pixelu v obrazové matici a I označuje jasovou hladinu příslušného pixelu. V následující deskripci je využito označení $I(r)$ pro diskrétní obrazovou matici. Předpokládá se, že $I(r)$ je označení pro analyzovaná obrazová data, jejichž struktura je obecně dána L regiony, které chceme extrahovat prahováním tak, abychom získali segmentovaný obraz, který je označen jako $M(r)$ aby:

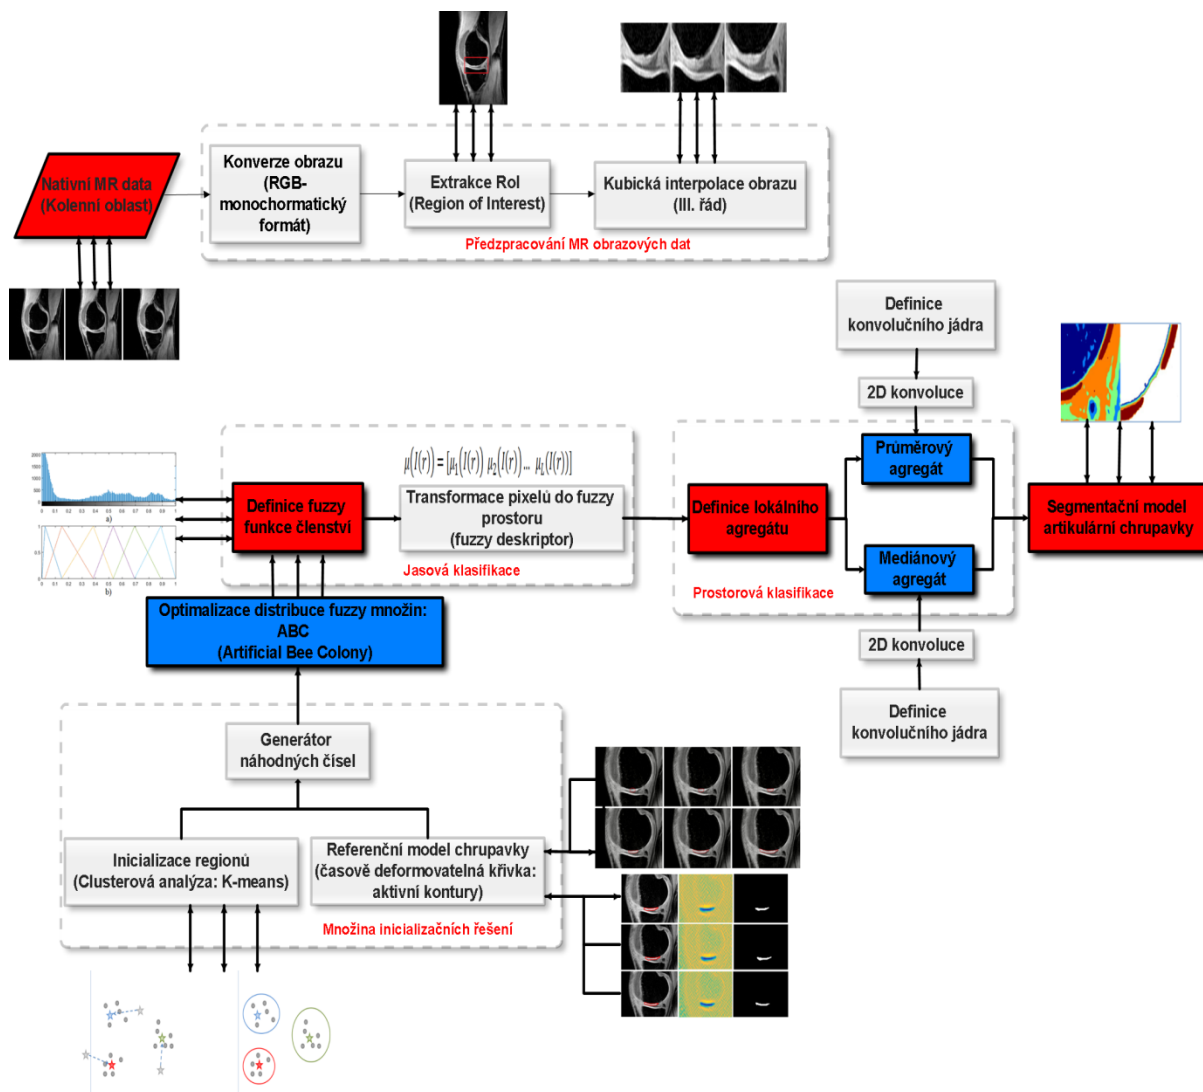
$$M(r) = g_s\{I(r)\} \quad (4.1)$$

kde $g_s\{\cdot\}$ označuje segmentační metodu, která může být považována za funkci, která mapuje N_I úrovní monochromatického obrazu $I(r)$ do L regionů, tzn. $g_s: N_I \rightarrow L$, kde $L < N_I$.

Pro provedení segmentace navrhovaná metodika předpokládá, že každý pixel obrazu $I(r)$ disponuje stupněm funkce členství v každém z L regionů. Tato funkce členství je modelována na základě využití fuzzy členské funkce.

V následujícím textu je využito označení $\mu_l(x), l=1, \dots, L$ pro fuzzy funkci členství l^{th} regionu. Prostorový agregát může být proto aplikován na tzv. „membership plane“, aby byla brána v úvahu relace mezi předešlými sousedními pixely k získání finální segmentace. [138, 139, A.4, A.5, A.9, A.12, A.13]

Metodologie, která je demonstrována na obrázku 55 reprezentuje komplexní strukturu navrhovaného řešení segmentace artikulárních chrupavek s ohledem na počínající patologické stavy artikulární chrupavky z MRI.



Obrazek 55 Komplexní struktura navrhované metodologie segmentace a modelování artikulární chrupavky. Zdroj: vlastní

4.3.1 Jasová klasifikace pixelů

Jak již bylo zmíněno na začátku kapitoly, metodika si klade za cíl extrakci oblasti artikulární chrupavky na základě barevného mapování povrchu s využitím tzv. soft klasifikace, kde na rozdíl od tzv. hard klasifikačních metod, které jednoznačně pixely klasifikují do konkrétních tříd, metoda využívá faktu, že každý obrazový pixel je popsán tzv. příznakovým vektorem, který je složen z fuzzy členských hodnot daného pixelu pro každou klasifikační třídu. To znamená, že např. pokud generujeme multiregionální segmentační model, obsahující 5 disjunktních oblastí, potom každý obrazový bod je popsán 5 hodnotami fuzzy členských funkcí. Podrobnější deskripce této metody je vysvětlena v rámci následujícího textu. Tento přístup však tvoří pouze první část segmentační metodologie. Metoda je doplněna o tzv. lokální agregát, který umožňuje modifikaci elementů každého z příznakových vektorů na základě lokální informace okolí. Tento krok přispívá k robustnosti metody zejména pro případy, kdy data jsou zanesena obrazovým šumem, což je jedna z příčin nekorektní klasifikace.

Fuzzy funkce členství $\mu_l(x)$, $l=1, \dots, L$ je přidružena ke každé z klasifikačních tříd, které jsou spojeny s definovanými centroidy. Metodika umožňuje dva přístupy generování segmentačního modelu, a sice na základě histogramové informace, a přístup využívající pouze extrakci centroidů, tudíž histogramová informace může být pomínuta. Z pochopitelných důvodů nutné znalosti příslušné distribuce jasových hodnot v histogramu se druhá alternativa jeví univerzálnějším způsobem. [146-148, A.4, A.6]

4.3.1.1 Funkce členství využívající obrazového histogramu

Tato alternativa následuje klasický přístup pro tzv. multiregionální segmentaci, kde hlavní úrovně obrazu jsou extrahovány z histogramu. Histogramová funkce je označována jako $h(I)$. Histogram $h(I)$ je aproximován na základě sumy L vážených distribucí:

$$h(I) \approx \sum_{l=1}^L \omega_l \cdot p_l(x; \theta_l) \quad (4.2)$$

kde $p_l(x; \theta_l)$ označuje hustotu rozložení pravděpodobnosti, která je definována setem parametrů θ_l a ω_l , představující váhové parametry, které splňují, že $\sum_l \omega_l = 1$. Aproximační procedura může být dána na základě využití minimalizačního algoritmu, jako je minimální střední kvadratická chyba (MMSE):

$$\arg \min_{\omega_l, \theta_l} \left| h(I) - \sum_{l=1}^L \omega_l \cdot p_l(x; \theta_l) \right| \quad (4.3)$$

Gaussova distribuce, která je dána $p_l(x; \theta_l)$, představuje relevantní alternativu pro reprezentaci histogramu. Nicméně, některé modality medicínských obrazových dat mohou být efektivněji zpracovávány s využitím alternativních distribucí. V případě zpracovávání obrazových dat z magnetické rezonance je známo, že tato data odpovídají Ricianově distribuci, což může být přesně aproximováno Gaussovou funkcí pro dosažení vysokého poměru odstupu signálu k šumu. Na druhou stranu ultrazvuková data jsou popisována na základě myriády distribucí, což je relevantně modelovatelné s využitím posloupnosti Gamma distribucí. Z tohoto důvodu je v těchto případech Gamma distribuce lepší kandidát než $p_l(x; \theta_l)$.

Záměrem této metodologie je využívání funkce členství místo pravděpodobnostních čísel. K tomuto závěru je využíván transfer od histogramové informace k modelu fuzzy množin, které poskytují informaci členství. Nejjednodušší cestou by bylo využití Gaussovy funkce členství (*GMF*). Přejechod z pravděpodobnosti k funkci členství je dán transformací první a poslední množiny, a také normalizací váhových parametrů.

Ačkoliv přirozený přechod ke *GMF* disponuje problémy, které jsou přidružené k teorii fuzzy množin: nejsou konzistentní a k průniku množin dochází pro hodnoty menší než 0.5. Z uvedených důvodů jsou kladeny následující požadavky na fuzzy množiny:


- Kompletní dělení: $\forall x, \exists \mu_l(x), 1 \leq l \leq L$, tak že $\mu_l(x) > 0$
- Konzistentnost: jestliže $\mu_l(x_0) = 1$, potom $\mu_k(x_0) = 0, \forall k \neq l$
- Normalita: $\max(\mu_l(x)) = 1$

- Křížení mezi sousedními fuzzy množinami je: $\mu_l(x_0) = \mu_{l+1}(x_0) = 0.5$ [143-149, A.17]

4.3.1.2 Funkce členství využívající triangulární funkce

Problémem předchozí metodiky je skutečnost, že je nutné řešit aproximační proceduru diskrétního histogramu spojitou funkcí na základě matematické optimalizace parametrů konkrétní distribuce. Z tohoto pohledu je každá aproximační metoda zatížena numerickou chybou, a navíc je vyloučené využít unifikovanou distribuci pro variabilní obrazová data. Tato metodika využívá faktu, že histogramová informace může být pomínuta. K těmto účelům je využívána pseudo trapezoidní funkce členství (Pseudo Trapezoid-Shaped (PTS)). Tato funkce může být generována přímo na základě centroidů. Toto představuje účelné řešení pro hlavní účel segmentace, nebo pro případy, kdy nedisponujeme přesnými znalostmi ohledně distribuce jasových hodnot objektů, či konkrétních tkání v obraze. [138], [143-149]

V následující deskripci centrální fuzzy množiny jsou zvoleny na základě trojúhelníkového tvaru (hlavní tvar PTS). Výstupem tohoto kroku je funkce členství, která popisuje každou z výstupních množin, $\mu_l(x)$, $l = 1, \dots, L$. Příklad posloupnosti PTS členských funkcí je ilustrována na obrázku 56. V tomto konkrétním případě je generován model, který obsahuje 4 segmentační třídy, které jsou determinovány posloupností vrcholů $V_1 - V_4$.



Obrázek 56 Posloupnost triangulárních funkcí členství specifikující jednotlivé obrazové regiony.
Zdroj: vlastní

4.3.1.3 Stanovení funkce členství

Členství pixelu r v obraze $I(r)$ v l -té třídě je dáno výrazem: $\mu_l(I(r))$. Využitím PTS funkce zároveň platí: $\sum_{l=1}^L \mu_l(I(r)) = 1$.

V tomto bodě inicializační prahování obrazu může být dáno na základě vztahu:

$$M(r) = \operatorname{argmax}_l \{\mu_l(I(r))\} \quad (4.4)$$

Kde $M(r)$ představuje výstup prahovaného obrazu. Nicméně, tímto způsobem není využita informace o okolí a výsledek je silně závislý na zvolené metodě nalezení centroidů. [138]

Výstup této fáze pro každý pixel je dán vektorem členských funkcí:

$$\mu(I(r)) = [\mu_1(I(r)) \ \mu_2(I(r)) \ \dots \ \mu_L(I(r))]$$

V případě využití PTS funkce členství platí, že pouze dva elementy každého vektoru jsou nenulové. [143-149, A.13, A.17]

4.3.2 Proces extrakce centroidů

Jednotlivé oblasti, které jsou generovány procesem segmentace, jsou definovány na základě využití L centroidů. Typicky platí, jak bylo zmíněno dříve: $L < N_l$. Počet centroidů může být předem manuálně nastaven uživatelem, alternativně algoritmus může být nastaven pro nalezení optimálního počtu segmentovaných regionů. Mnoho regionálních segmentačních metod, které jsou publikovány v literatuře, které využívají pevné prahování, mohou být obecně využity v tomto inicializačním kroku, obzvláště metody, které jsou založeny na klastrování. Nicméně stěžejním problémem klastrovacích metod je inicializační volba těžiště. V rámci navrhovaného řešení segmentace kolenní chrupavky je využito hybridního přístupu pro nalezení lokalizace centroidů na základě metody K-means, referenčního modelu a *ABC* (Artificial Bee Colony) algoritmu. K-means spadá do oblasti shlukové analýzy a klasifikuje data do jednotlivých klastrů v závislosti na jejich Euklidově vzdálenosti od příslušného těžiště. Z metody K means jsou brána pouze detekovaná těžiště, která následně slouží pro formování sekvence fuzzy členských funkcí, aproximující jednotlivé obrazové regiony. Tyto těžiště indikují regiony mimo chrupavku. Referenční model chrupavky vytváří tzv. ‘Ground Truth’, reprezentující ideální model určité části fyziologické chrupavky. Mediánový odhad jasového spektra takového modelu je využit pro indikaci těžiště chrupavky. Segmentační model na bázi jasové klasifikace je hledán pomocí optimalizační procedury, která je dána *ABC* algoritmem, která v rámci přednastavené evoluce postupně fitness funkcí ohodnocuje jednotlivá přípustná řešení inicializační volby těžišť. [A.18]

4.3.3 Algoritmus K means

Algoritmus iterativně hledá hodnoty vektorů tak, že minimalizuje střední odchylku mezi zadanou množinou dat (pixelů) a vektory (vzdálenost bodu od etalonu shluku), které mají k těmto datům nejmenší euklidovskou vzdálenost a rozděluje je do předem daného počtu shluků (tříd) $K: C_1, C_2, \dots, C_k$.

Základní algoritmus využívá euklidovskou vzdálenost a μ_j představuje aritmetický průměr bodů ve shluku (střední hodnota ve třídě) – etalon.

Vstupem algoritmu je množina pixelů x_1, x_2, \dots, x_l a konstanta K udává počet vektorů. V inicializační fázi algoritmu se inicializují vektory $\mu_j, j = 1, \dots, k$. Inicializační poloha vektorů μ_j je dána ekvidistálním dělením histogramu na K úrovní. Po inicializaci se začnou iterativně opakovat následující dva kroky:

Klasifikace: Všechny pixely $x_i, i = 1, \dots, l$ jsou klasifikovány do tříd, které jsou určeny vektory $\mu_i, i = 1, \dots, k$ na základě minima euklidovské vzdálenosti. Tedy pixel x_i je přiřazen do třídy y_i , podle vztahu:

$$y_i = \arg \min_j \|x_i - \mu_j\| \quad (4.5)$$

Přepočítání vektorů: Vypočítají se nové hodnoty vektorů μ_j jako střední hodnoty z pixelů x_i , které byly klasifikovány do třídy, určené příslušným vektorem μ_j . Tedy nová hodnota μ_j je spočítána dle vztahu:

$$\mu_j = \frac{1}{l_j} \sum_{i=1, y_i=j}^l (x_i) \quad (4.6)$$

kde l_j představuje počet pixelů x_i klasifikovaných v druhém kroku do třídy určené vektorem μ_j . Kroky 1 a 2 se opakují do té doby, dokud se alespoň jeden vektor x_i klasifikuje do jiné třídy, než byl klasifikován v předcházejícím kroku. Centroid v každé třídě je určen jako pixel, který disponuje maximální četností. [140-142]

Výhodou metody K means je fakt, že metoda není náročná z hlediska velkého množství dat. Je zde konkrétní požadavek ohledně úložného prostoru: $O((m+K)n)$, kde m je počet bodů a n je počet atributů. Komputační náročnost je rovněž nenáročná. Výpočetní čas metody je dán, jako: $O(I*K*m*n)$, kde I je počet iterací, požadovaných pro konvergenci. K means je lineární operace vůči parametru m a je rovněž efektivní pro jednoduché klastrování dat do K klastrů, kde K je signifikantně nižší, než m . [141]

4.3.4 Referenční model artikulární chrupavky


Referenční model artikulární chrupavky je rovněž využit pro inicializační volbu těžiště jasové segmentace s cílem rychlejší konvergence optimalizační metodologie. Ideální model chrupavky by měl dostatečně reprezentovat jasové vlastnosti pixelů, které tvoří strukturu artikulární chrupavky. K tomuto účelu je analyzováno 100 MR PD sekvence obrazových záznamů artikulární chrupavky s cílem identifikace její struktury. K tomuto účelu je využíváno metody aktivních kontur, umožňující automatickou segmentaci oblasti chrupavek. Tento model je následně komparován s manuální segmentací s cílem jeho verifikace. Jak již bylo zmíněno, struktura fyziologické artikulární chrupavky představuje v zásadě homogenní strukturu, která se vyznačuje jen slabými jasovými fluktuacemi. Tento fakt se dá efektivně využít v oblasti aktivních kontur, neboť tyto křivky se dobře šíří v homogenním prostředí. Navíc při vhodné volbě inicializačních parametrů je možné docílit, aby kontura byla terminována na hranici fyziologické chrupavky.

Z obecného hlediska aktivní kontury představují časově deformovatelné křivky se schopností se adaptovat analyzovanému objektu. V inicializační fázi je nutné specifikovat inicializační křivku, která postupně mění své geometrické parametry směrem k hranám fyziologické chrupavky. Inicializační křivka by měla dobře reflektovat tvar analyzovaného objektu. Dle typických geometrických vlastností chrupavky je využíváno elipsy, která se iteračně expanduje. Segmentační metoda využívá následujících parametrů:

- **numiter** – počet iteračních kroků.
- **timestep** – časový krok posunu křivky (čím vyšší je hodnota parametru, tím rychleji se křivka pohybuje, ale s většími nepřesnostmi).
- **mu** – konstanta, která zajišťuje, aby se křivka neodchýlila příliš daleko od své aktuální pozice během své evoluce.

- **alf** – konstanta, díky které lze nastavit důraz (při evoluci) kladený na energii obrazu, která přitahuje křivku ke hranám.
- **nu** – ovlivňuje délku kontury. Čím je hodnota tohoto parametru nižší, tím větší délky může kontura při své evoluci nabývat, ale naopak může být přitahována nežádoucími artefakty obrazu.
- **c0** – touto konstantou se násobí hodnoty pixelů uvnitř kontury (její zápornou hodnotou) a zvětší kontury (její kladnou hodnotou). Vyšší hodnota zajišťuje rychlejší počáteční pohyb inicializované kontury.
- **epsilon** – udává profil Diracova impulsu, který zrychluje počáteční pohyb inicializované kontury. Čím vyšších hodnot nabývá, tím méně přesná je finální kontura.
- **sigma** – jedná se o parametr Kernelovy funkce, která částečně řeší nehomogenitu jasové intenzity. Čím je hodnota parametru vyšší, tím více se křivka při své evoluci vzdaluje od své aktuální pozice během jednoho iteračního kroku.
- **lambda1** – koeficient, který přiřazuje váhu oblasti uvnitř kontury při pohybu křivky.
- **lambda2** – koeficient, který přiřazuje váhu oblasti vně kontury při pohybu křivky.


U parametrů *lambda1* a *lambda2* záleží také kromě hodnoty na jejich vzájemném poměru. Pokud je hodnota parametru *lambda1* větší než hodnota *lambda2*, má křivka tendenci se smršťovat. [A.1] Pokud je nerovnost opačná, má křivka tendenci expandovat. Následující výstup (Obr. 57) demonstruje aplikaci aktivních kontur na artikulární chrupavku. Sekvence obrazových výstupů reflektuje evoluci kontury od inicializační elipsy až po finální aproximaci artikulární chrupavky.




Obrázek 57 Evoluce aktivní kontury od inicializační elipsy až po finální konturu. Zdroj: vlastní

První částí této procedury je klasifikace oblasti artikulární chrupavky na základě aktivních kontur (oblast aktivní kontury je indikována červeně). Klíčovým výstupem referenčního modelu má být deskriptor, popisující relace pixelů uvnitř artikulární chrupavky. To znamená, že je nezbytné, aby model umožňoval extrakci oblasti jasového spektra artikulární chrupavky. Na základě uzavřené křivky indikované červeně je možné specifikovat tzv. region kontury. K tomuto účelu slouží tzv. energetická mapa aktivních kontur. Energetická mapa dobře klasifikuje oblast aktivní kontury na dvě disjunctní části dle hodnot energie. Jedná se o jistý druh transformace originálních jasových hodnot pixelů na hodnoty energie. Zde platí, že pixely, ležící uvnitř kontury, jsou indikovány zápornou energií, naproti tomu pixely, ležící vně kontury jsou indikovány kladnou energií. Pixely ležící na hranici, mají nulovou energii. Na základě tohoto přístupu je snadným úkolem specifikovat binární matematický model

reflektující oblast aktivní kontury (bílá barva) a obrazové pozadí (červená barva). Následující výstupy indikují testování aktivní kontury pro nativní MR obrazová data a jejich extrakt ve formě RoI.




Obrázek 58 Naivní data (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo).
Zdroj: vlastní




Obrázek 59 Naivní data - RoI (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). Zdroj: vlastní

Samozřejmostí je, že segmentační procedura, generující podklad pro model distribuce jasových hodnot artikulární chrupavky by měla být co nejrobustnější, zejména v kontextu jiných obrazových sekvencí. Proto je algoritmus testován rovněž na variabilních MR sekvencích rychlé spinové echo (T1 vážený obraz a proton-denzní obraz bez metody potlačení tuku) a 3D gradientní echo. V zásadě se dá předpokládat vysoká efektivita řešení, neboť i na jiných sekvencích artikulární chrupavka vykazuje


vysokou jasovou homogenitu. Následující výstupy (Obr. 60-62) indikují testování aktivních kontur na zmíněných sekvencích. [A.18, A.19]



Obrázek 60 Naivní data: rychlé spinové echo, T1 vážený obraz (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). Zdroj: vlastní




Obrázek 61 Naivní data: 3D gradientní echo (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). Zdroj: vlastní



Obrázek 62 Naivní data: rychlé spinové echo, proto-denšní obraz, bez potlačení tuku (vlevo), energetická mapa (uprostřed) a binární model aktivní kontury (vpravo). Zdroj: vlastní

4.3.4.1 Validace referenčního modelu

Efektivita každé segmentační metody by měla být validována. Validace by měla reflektovat zejména přesnost příslušné metody. V oblasti segmentace artikulární chrupavky se validace standardně provádí manuálně. Validační skóre využívá diferenci plochy pixelů mezi automatickou a manuální segmentací. Aby bylo možno maximálně potlačit lidský faktor, každá manuální segmentace byla prováděna třikrát, přičemž se bral příslušný průměr. Výstupem manuální segmentace je rovněž binární model, který je stavěn jako protiváha metodě aktivních kontur. Následující výstup (Obr. 63) indikuje proces manuální segmentace.



Obrázek 63 Indikace manuální segmentace (vlevo) a binární model artikuléární chrupavky (vpravo).
Zdroj: vlastní

Následující výstup (Obr. 64) demonstuje komparaci binárního modelu chrupavky na základě metody aktivních kontur (vlevo) a modelu chrupavky, generovaného manuální segmentací (vpravo). Z hlediska geometrické reprezentace jsou difference minimální, podobných výsledků bylo dosaženo v rámci testování celého datasetu.



Obrázek 64 Komparace automatické segmentace artikuléární chrupavky na základě metody aktivních kontur (vlevo) a manuální segmentace (vpravo). Zdroj: vlastní

Následující tabulka uvádí příklad testování referenčního modelu pro nativní MR obrazová data. Aby byl alespoň částečně potlačen vliv lidského faktoru, manuální segmentace je pro každý případ opakována třikrát. Výsledek je dán průměrováním jednotlivých pokusů.

Tabulka 1 Validace metody aktivních kontur pro nativní MR data.

Snímek	Rozlišení snímku [px]	Plocha chrupavky automatickou segmentací [px]	Plocha chrupavky manuální segmentací [px]		Rozdíl [px]	Průměrný procentuální rozdíl [%]
1.	256x256	154	1.	136	18	
			2.	141	13	
			3.	145	9	
			Průměr:	140.6	13.3	9.5
2.	256x256	150	1.	155	5	
			2.	163	13	
			3.	162	12	
			Průměr:	160	10	6.2
3.	256x256	122	1.	139	17	
			2.	136	14	
			3.	142	20	
			Průměr:	139	17	12.2
4.	256x256	142	1.	171	29	
			2.	165	23	
			3.	164	22	
			Průměr:	166.6	24.6	14.8
5.	256x256	152	1.	174	22	
			2.	181	29	
			3.	177	25	
			Průměr:	177.3	25.333	14.3
Průměrné hodnoty všech snímků:					18.1	11.4

V rámci testování je využito snímků, majících stejné unifikované rozlišení (256x256 px). Důležitým indikátorem testování efektivity segmentace je průměrná odchylka metody aktivních kontur, která představuje 18.1 pixelů. V tomto kontextu může tento údaj být vztažen vůči průměrné ploše chrupavky (144 px), což představuje 12.5 %. [A.11, A.15, A.18]

4.3.5 Geneze ideálního modelu chrupavky

Předchozí kapitola pojednává o alternativní segmentační proceduře na bázi aktivních kontur, která si klade za cíl extrakci oblasti artikulární chrupavky, kde lze předpokládat fyziologické vlastnosti. Výstupem takovéto segmentační procedury je binární matematický model, klasifikující pixely do dvou oblastí: artikulární chrupavka (bílá) a obrazové pozadí (černá). Násobením binárního modelu s originální obrazovou doménou je dosaženo modelu chrupavky v originální oblasti. Ideální model chrupavky by měl reflektovat oblast histogramu takovéhoho modelu pomocí dvou parametrů, využívaných pro fitness funkci. Zejména se jedná o definici těžiště na základě modusu histogramu vymezeného fuzzy množinou. Druhý parametr specifikuje variabilitu pixelů uvnitř fuzzy množiny. Variabilita je určena statistickým rozptylem, přičemž se předpokládá, že fyziologická artikulární chrupavka dosahuje vysokého stupně homogenity, tzn., že rozptyl by měl být minimalizován. Pro ideální model chrupavky je generován statistický odhad intervalu rozptylu a střední hodnoty na základě vzorku 150 záznamů.

Oboustranný intervalový odhad náhodné veličiny χ^2 lze zapsat pravděpodobnostní rovnicí:

$$P\left(\chi_{1-\frac{p}{2}}^2(n-1) \leq \chi^2 \leq \chi_{\frac{p}{2}}^2(n-1)\right) = 1 - p \quad (4.7)$$

Po úpravě dostaneme:

$$P\left(\chi_{1-\frac{p}{2}}^2(n-1) \leq \frac{(n-1)s^2}{\sigma^2} \leq \chi_{\frac{p}{2}}^2(n-1)\right) = 1 - p \quad (4.8)$$

Po úpravě získáme pravděpodobnostní rovnici pro intervalový odhad rozptylu základního souboru ve tvaru:

$$P\left(\frac{(n-1)s^2}{\chi_{\frac{p}{2}}^2(n-1)} \leq \sigma^2 \leq \frac{(n-1)s^2}{\chi_{1-\frac{p}{2}}^2(n-1)}\right) = 1 - p \quad (4.9)$$

V rámci testovaného datasetu ($n=150$) artikulárních chrupavek byl zjištěn rozptyl 678.9. Intervalový odhad rozptylu distribuce jasových hodnot je kalkulován:

$$\frac{149 * 678.9}{178.4} \leq \sigma^2 \leq \frac{149 * 678.9}{121.7}$$

$$567.011 \leq \sigma^2 \leq 831.19$$

Parametr, určující těžiště fuzzy množiny, je medián. Korektní volba tohoto parametru je důležitá v kontextu volby inicializačních těžišť. Tento odhad je brán jako inicializační informace pro ABC algoritmus, generující inicializační těžiště. Intervalový odhad mediánu se spolehlivostí 95%, kde $\alpha = 5\%$ se odhaduje z interkvartilového rozpětí jako:

$$\left\langle \hat{x}_{0.5} - 1.57 \frac{(\hat{x}_{0.75} - \hat{x}_{0.25})}{\sqrt{n}}; \hat{x}_{0.5} + 1.57 \frac{(\hat{x}_{0.75} - \hat{x}_{0.25})}{\sqrt{n}} \right\rangle \quad (4.10)$$

Kde x_p jsou 100 p% výběrové kvantily. Odhad mediánu je kalkulován pro výběrový soubor $n=150$ patientských záznamů z celkového počtu $N=3500$ záznamů. Tímto faktem je splněna podmínka pro rozsah souboru:

$$150 < 0.05 * 3500$$

Parametry intervalového odhadu mediánu jsou následující:

$$\hat{x}_{0.25} = 204.39$$

$$\hat{x}_{0.5} = 210.96$$

$$\hat{x}_{0.75} = 215.33$$

$$n = 150$$

Intervalový odhad mediánu je kalkulován na základě vztahu 4.10 následujícím způsobem:

$$\left\langle 210.96 - 1.57 \frac{(215.33 - 204.39)}{\sqrt{150}}; 210.96 + 1.57 \frac{(215.33 - 204.39)}{\sqrt{150}} \right\rangle$$

$$\langle 209.54; 212.37 \rangle$$

Druhou alternativou pro estimaci mediánu jasového spektra fyziologické artikulární chrupavky je Gastwirthuv medián. Gastwirthuv medián je kalkulován na základě výběrového mediánu, dolního a horního tercilu. Bodový odhad je dán vztahem:

$$\hat{x}_{GST} = 0.4 \cdot \hat{x}_{0.5} + 0.3 \cdot (\hat{x}_{0.33} + \hat{x}_{0.66}) \quad (4.11)$$

Intervalový odhad Gastwirthova mediánu se spolehlivostí 95 % je dán vztahem:

$$\left\langle \hat{x}_{GST} - 1.57 \frac{\hat{x}_{0.75} - \hat{x}_{0.25}}{\sqrt{n}}; \hat{x}_{GST} + 1.57 \frac{\hat{x}_{0.75} - \hat{x}_{0.25}}{\sqrt{n}} \right\rangle \quad (4.12)$$

Parametry pro kalkulaci Gastwirthova mediánu jsou definovány následujícím způsobem:

$$\hat{x}_{0.5} = 210.96$$

$$\hat{x}_{0.33} = 207.043$$

$$\hat{x}_{0.66} = 213.49$$

$$\hat{x}_{GST} = 210.54$$

Gastwirthuv medián je kalkulován následujícím způsobem:

$$\left\langle 210.54 - 1.57 \frac{215.33 - 204.39}{\sqrt{150}}; 210.54 + 1.57 \frac{215.33 - 204.39}{\sqrt{150}} \right\rangle$$

$$\langle 209.12; 211.95 \rangle$$

Druhou komparativní mezí vůči mediánovému odhadu je interval střední hodnoty. Testování probíhá na stejném datasetu 150 MR záznamů. Tato technika vyžaduje ověření faktu, že data pocházejí z normálního rozdělení. Normalita dat je provedena na základě čistého testu významnosti. Nulová a alternativní hypotéza je formulována ve tvaru:

H_0 : Jasové spektrum fyziologické chrupavky nabývá normálního rozdělení.

H_A : Jasové spektrum fyziologické chrupavky nenabývá normálního rozdělení.

Normální rozdělení má dva parametry: μ a σ^2 . Ani jeden z nich není v nulové hypotéze specifikován, jedná se neúplně specifikovaný test (počet odhadovaných parametrů $h=2$). Nejlepším odhadem střední hodnoty μ je výběrový průměr \bar{x} , nejlepším odhadem rozptylu σ^2 je výběrový rozptyl s^2 . Tyto parametry jsou dány:

$$\bar{x} = 210.24$$

$$s^2 = 61.11$$

V prvním kroku je potřeba testované rozdělení kategorizovat. Data jsou rozdělena do 7 třídících intervalů, pro které jsou určeny empirické četnosti O_i , očekávané pravděpodobnosti π_{0i} a očekávané četnosti E_i (Tab. 2).

Tabulka 2 Parametry třídících intervalů distribuce jasového spektra artikulární chrupavky.

i	Třídící interval [%]	O_i	π_{0i}	E_i
1	(188.8;198.5)	12	0.081	12.2
2	(198.5;203.4)	18	0.13	19.7
3	(203.4; 208.3)	34	0.208	31.2
4	(208.3; 213.1)	30	0.23	35.1
5	(213.1; 218.1)	38	0.18	27.8
6	(218.1; 222.9)	13	0.103	15.5
7	(222.9; 237.5)	5	0.068	8.2
celkem	-	150	1	-

P – hodnota tohoto testu je 0.15 (>0.05), proto nezamítáme nulovou hypotézu. Jasová distribuce fyziologické artikulární chrupavky vykazuje normální rozdělení.

Intervalový odhad střední hodnoty pro kalcifikované cévy je kalkulován pro spolehlivost:

$$1 - \alpha = 0.95$$

Na hladině významnosti:

$$\alpha = 0.05$$

$$\frac{\alpha}{2} = 0.025, 1 - \frac{\alpha}{2} = 0.975$$

$$z_{0,975} = 1.96$$

Oboustranný intervalový odhad střední hodnoty je vypočten dle vztahu:

$$\mu \in \left\langle \bar{x} - \frac{\sigma_x}{\sqrt{n}} z_{1-\frac{\alpha}{2}}; \bar{x} + \frac{\sigma_x}{\sqrt{n}} z_{1-\frac{\alpha}{2}} \right\rangle$$

$$\mu \in \left\langle 210.24 - \frac{61.11}{\sqrt{150}} 1.96; 210.24 + \frac{61.11}{\sqrt{150}} 1.96 \right\rangle$$

$$\mu \in \langle 200.46; 220.019 \rangle$$

Tabulka 3 sumarizuje komparativní analýzu odhadu mediánu, Gastwirthova mediánu a střední hodnoty. Je zřejmé, že mediánové odhady nevykazují signifikantní diference, oproti odhadu střední hodnoty, který je reprezentován širším intervalem. [A.16, A.20]

Tabulka 3 Komparace intervalových odhadů jasové distribuce artikulární chrupavky.

	Jasová distribuce artikulární chrupavky
Odhad mediánu	$\langle 209.54; 212.37 \rangle$
Odhad Gastwirthova mediánu	$\langle 209.12; 211.95 \rangle$
Odhad střední hodnoty	$\langle 200.46; 220.019 \rangle$

4.3.6 Optimalizace fuzzy členských funkcí

Jasová segmentace se opírá o genezi posloupnosti trojúhelníkovitých fuzzy členských funkcí, sloužící pro specifikaci jednotlivých regionů multiregionálního segmentačního modelu. Trojúhelníkovité funkce se jeví jako relevantní alternativa pro aproximaci jasových regionů. Výhodou tohoto přístupu je zejména snadná aplikovatelnost tohoto typu fuzzy funkcí. V tomto kontextu je trojúhelníkovitá funkce dána svým vrcholem, předpokládající lokaci těžiště příslušného regionu. Klíčovou fází této části segmentační metody, zároveň předurčující efektivitu celé metodologie, je relevantní lokace těžiště, aproximující oblast artikulární chrupavky. Zde se využívá hybridního přístupu, obsahujícího inicializaci na bázi metody K means, referenčního modelu chrupavky a genetického algoritmu.

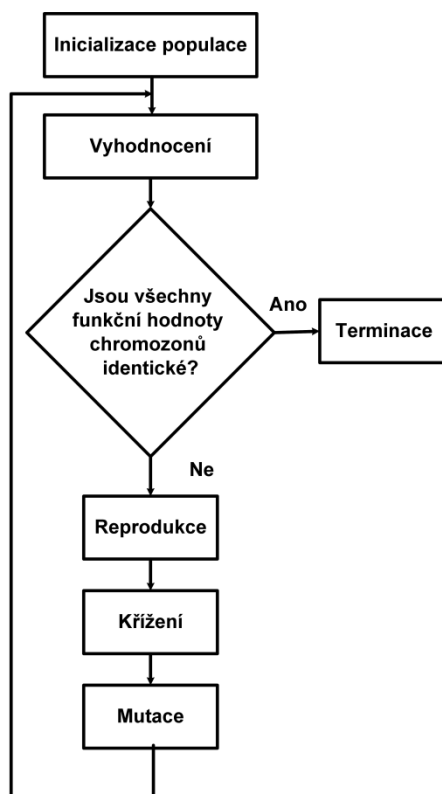
Jak již bylo zmíněno v předchozím textu, stěžejní nevýhodou metody K means je inicializační volba těžišť. Při nevhodné volbě těžišť se může stát, že algoritmus nedosáhne relevantní konvergence, což následně může zapříčinit nepřesnou aproximaci oblasti artikulární chrupavky. Důležitým faktem prosté metody K means je skutečnost, že tato metoda nijak nevyužívá vlastností, které by specifikovaly artikulární chrupavku, ale pouze hledá těžiště shluku pixelů na základě minimalizace jejich vzdálenosti. V rámci metodologie je využíváno inicializačního kroku na základě metody K means s cílem přibližné lokace jednotlivých těžišť, specifikující segmentační třídy mimo artikulární chrupavku. To znamená, že z metody K means je využita pouze informace o jednotlivých těžištích. V metodě K means jsou těžiště inicializována na základě ekvidistálního dělení jasové stupnice. Následně je aplikován optimalizační algoritmus, pracující na bázi evolučního přístupu, postupně aproximujícího lokaci těžiště.

V rámci jasové klasifikace je využíváno ABC algoritmu, jakožto genetického algoritmu hledajícího evoluci jednotlivých přípustných řešení optimalizačního problému. V tomto konkrétním případě se jedná o optimální lokalizaci trojúhelníkovitých fuzzy členských funkcí. Tato optimalizační procedura je spjata s optimalizační fitness funkcí, ohodnocující jednotlivá řešení. Tato fitness funkce by měla využívat parametry, relevantně popisující kritéria optimalizovaného problému. V tomto případě se jedná o obrazové regiony, charakterizující artikulární chrupavku a přilehlé tkáň.

4.3.7 ABC algoritmus využívající modifikovanou fitness funkci

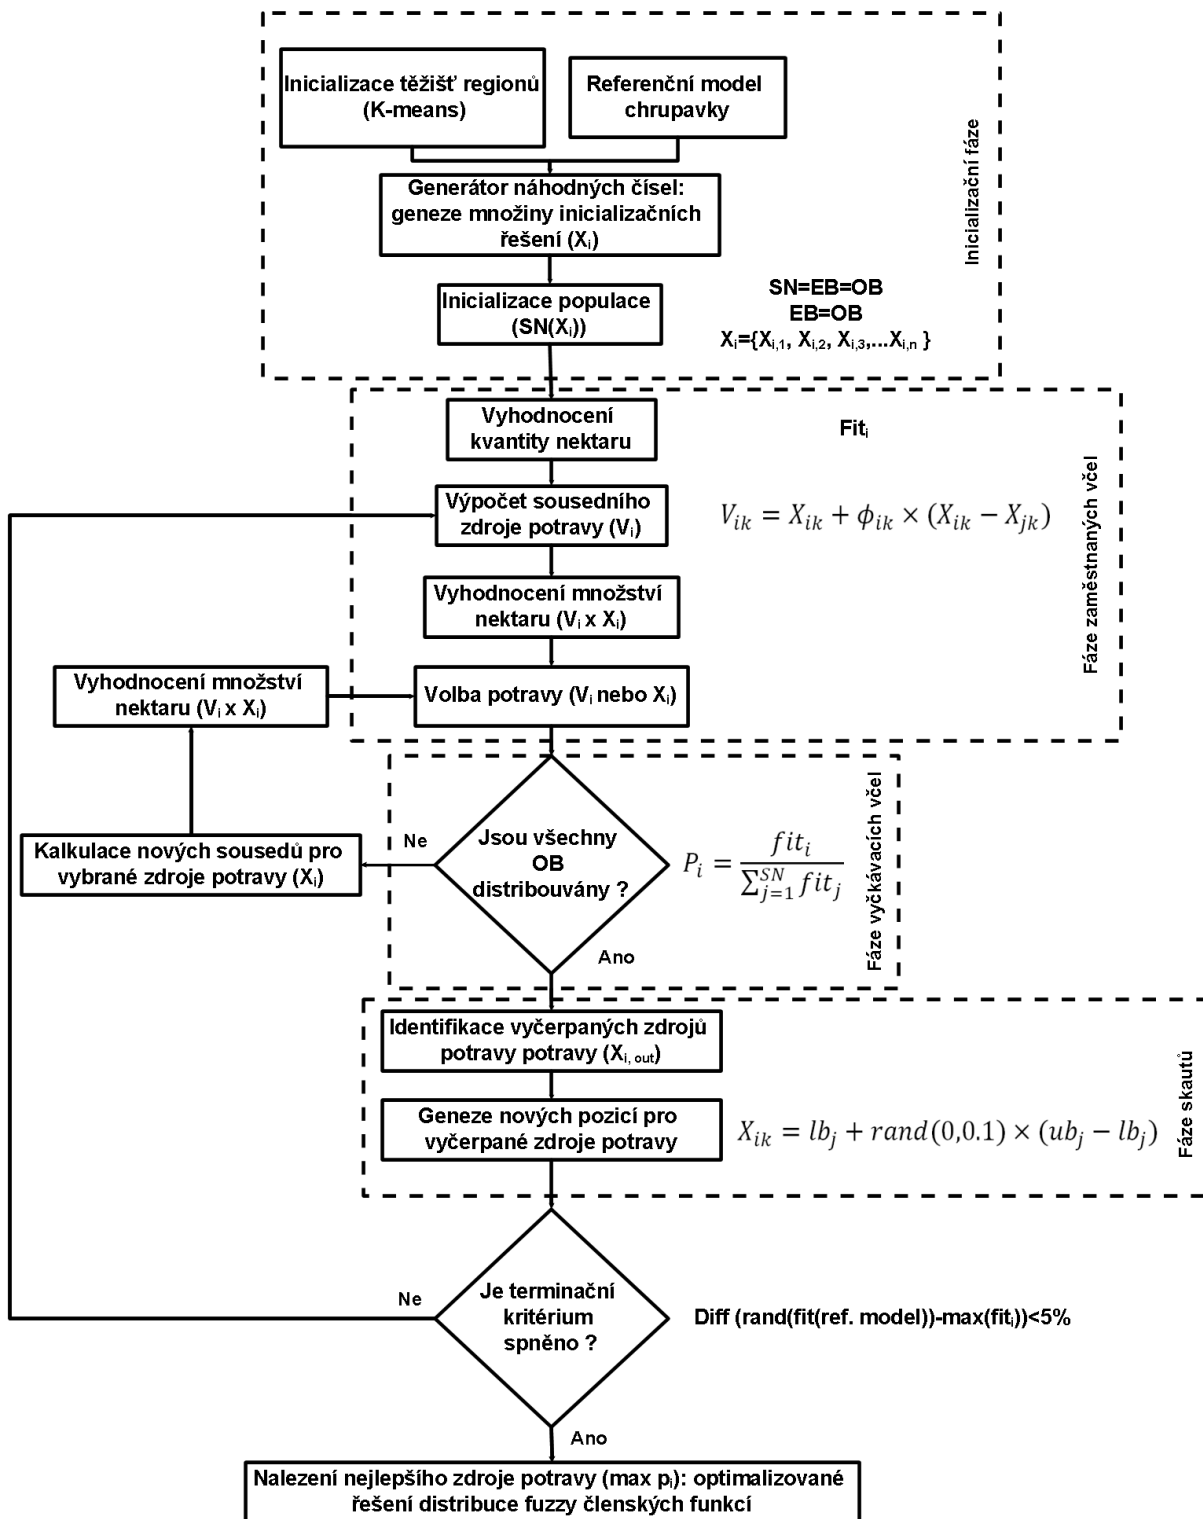
Z obecného hlediska představuje genetický algoritmus (GA) heuristický přístup, který na základě principů evoluční biologie hledá řešení složitých problémů, pro které neexistuje použitelný exaktní algoritmus. GA patří do skupiny tzv. evolučních algoritmů, využívajících strategií, napodobující evoluční procesy z biologie, mezi které patří dědičnost, mutace, přirozený výběr a křížení (Obr. 65). Tyto techniky jsou využívány pro řešení zadané úlohy. Jedním z takových principů je ABC

algoritmus, který je v rámci metodologie aplikován s cílem optimálnější aproximace histogramu, než je tomu pouze u prosté metody K means, sekvencí trojúhelníkovitých fuzzy členských funkcí.



Obrázek 65 Obecná struktura genetického algoritmu. Zdroj: vlastní

ABC (Artificial Bee Colony) optimalizační algoritmus je inspirován rojem včel, hledajících potravu. *ABC* využívá syntetických včel, které jsou klasifikovány do třech kategorií: zaměstnané včely (*EB*), vyčkávací včely (*OB*) a skauti (*SB*). Obrázek 66 reprezentuje komplexní strukturu *ABC* algoritmu, podrobnější popis této optimalizační procedury je popsán v následujícím textu.



Obrázek 66 Komplexní struktura ABC algoritmu pro optimalizaci soft prahovací metodologie.
Zdroj: vlastní

Celková populace (SN) se skládá se stejného počtu EB a OB . Předpokládá se, že na jednu zaměstnanou včelu (EB) připadá jeden zdroj potravy. Počet zaměstnaných včel a zdrojů potravy lze modelovat následujícím způsobem:

$$EB = [EB_1, EB_2, EB_3, \dots, EB_n]$$

$$S = [S_1, S_2, S_3, \dots, S_m]$$

Jinými slovy mezi počtem zaměstnaných včel a počtem zdrojů platí: $m = n$. Parametr $X_i = \{X_{i,1}, X_{i,2}, \dots, X_{i,p}\}$ reprezentuje i -té řešení v hejnu včel, kde p vyjadřuje velikost dimenze, neboli také počet parametrů, které se optimalizují. V případě multiregionální segmentace parametr p vyjadřuje počet vrcholů trojúhelníkovitých fuzzy členských funkcí, které jsou v rámci ABC strategie optimalizovány, neboli také počet segmentačních množin. První fázi algoritmu ABC jsou zaměstnané včely. Každá EB generuje nové kandidátní řešení V_i v sousedství X_i . Kandidátní řešení V_i je dáno následujícím výrazem:

$$V_{ik} = X_{ik} + \phi_{ik} \times (X_{ik} - X_{jk})$$

kde X_{jk} představuje náhodné kandidátní řešení ($i \neq j$), k představuje náhodný index, pro který platí: $k \in \{1, 2, \dots, p\}$ a funkce ϕ_{ik} je dána generátorem náhodných čísel v intervalu $[-0.1; 0.1]$. Jakmile je generováno řešení V_i , je přistoupeno k účelové selekci na základě fitness funkce (fit_i) mezi řešeními X_i a V_i . V případě, že fitness funkce řešení V_i je lepší než X_i , potom je uchováno jako nové řešení této dvojice. V opačném případě zůstává X_i nezměněno. Tato výběrová metodika je aplikována pro všechna řešení X_i . V tomto procesu platí, že jedna EB na základě hodnoty fitness funkce vybírá optimálnější ze dvou řešení. V této fázi metody se uplatňuje limit výběru L_v . Jedná se o parametr, který udává maximální počet pokusů nových kandidátních řešení k X_i , když nelze nalézt optimálnější řešení V_i . V rámci metodologie je využito $L_v = 10$. Po vyčerpání parametru L_v je zdroj považován za vyčerpaný. V druhé fázi metody je přistoupeno k vyčkávacím včelám (OB), které testují a ohodnocují jednotlivá řešení z globálního pohledu. Tato probabilistická selekce, označovaná jako ruská ruleta, prováděná OB , je dána vztahem:

$$P_i = \frac{fit_i}{\sum_{j=1}^{SN} fit_j} \quad (4.13)$$

kde fit_i reprezentuje fitness hodnotu i -tého řešení a SN představuje velikost populace. Předpokládá se, že optimálnější řešení disponuje vyšší hodnotou P_i . Až je vybrán zdroj potravy X_i , je určen sousední zdroj potravy V_i a jejich fitness hodnoty jsou komparovány. Stejně jako u první fáze je vybrána hodnota s vyšší hladinou fitness funkce. Finální fázi algoritmu jsou skauti, kteří hledají nové zdroje potravy místo vyčerpaných zdrojů. Za předpokladu, že označíme vyčerpaný zdroj potravy jako X_i , potom skaut (SB) objeví nový zdroj potravy místo vyčerpaného zdroje. A celý proces ohodnocování řešení se opakuje, v rámci přednastaveného počtu cyklů (NC), v rámci metodologie je využito $NC = 100$. Nový zdroj potravy je dán výrazem:

$$X_{ik} = lb_j + rand(0,0.1) \times (ub_j - lb_j) \quad (4.14)$$

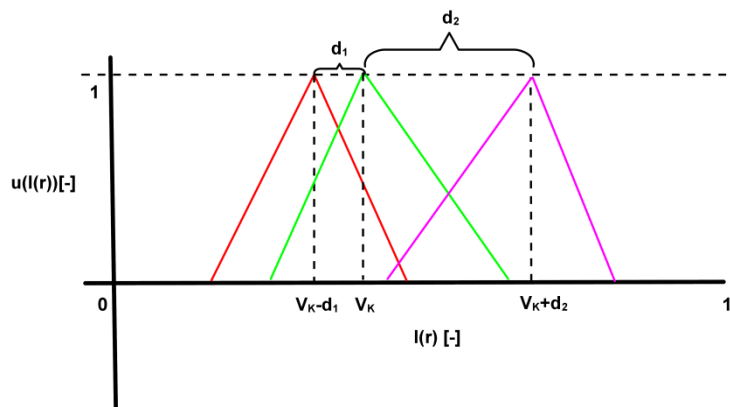
kde $rand(0,0.1)$ reprezentuje náhodné číslo z intervalu $[0; 0.1]$ pocházející z normálního rozdělení a lb, ub reprezentují dolní a horní limit i -té dimenze. V rámci segmentační metodologie tyto meze tvoří omezení normalizovaného jasového spektra (0-1 úrovní šedi). Výstupem této optimalizační metody je množina všech přípustných řešení, která jsou ohodnocena. Ve finálním kroku je vybíráno řešení disponující maximální hodnotou P_i . [155, A.17]

4.3.7.1 Extrakce příznaků na základě fitness funkce

Stěžejní částí algoritmu ABC je fitness funkce, průběžně ohodnocující jednotlivá přípustná řešení optimalizačního problému. V rámci globální optimalizační procedury je optimalizována diskrétní funkce, reprezentující model distribuce fuzzy množin:

$$f(V) = (V_1, V_2, \dots, V_{p-1}, V_p) \quad (4.15)$$

kde p koresponduje s počtem trojúhelníkových fuzzy množin a V označuje vektor vrcholů těchto příslušných množin. Jsou stanoveny omezující podmínky pro hledání optimálního řešení: $lb = 0, ub = 1$. Hlavním smyslem optimalizační procedury je ideální distribuce fuzzy množin charakterizující fyziologickou a patologickou oblast chrupavky s cílem minimalizace optimalizačního kritéria. Obecně se předpokládá, že pro každou segmentační třídu můžeme definovat k alternativ, které hůře či lépe reflektují vlastnosti konkrétní kolenní tkáň. Finálně je vybrána alternativa, která dle nastavených kritérií nejlépe reflektuje příslušnou tkáň. Tato situace (pro V_k množinu segmentačního modelu) je ilustrativně demonstrována na Obr. 67. Klíčovým aspektem celé optimalizační strategie je kritériální (fitness) funkce, která z globálního pohledu příslušnou segmentační množinu ohodnocuje.



Obrázek 67 Optimalizace těžiště (V_k) segmentační třídy. Zdroj: vlastní

Důležitým aspektem je optimalizační kritérium, definující fitness funkci. Teoreticky může být použita konečná množina příznaků charakterizující obrazovou manifestaci artikulární chrupavky. Může se jednat o např. geometrické, nebo jasové profily příslušného regionu. V rámci metodologie se fitness funkce opírá o jasový profil artikulární chrupavky. Tento profil je charakterizovaný statistickými vlastnostmi regionu.

Artikulární chrupavka z hlediska fyziologie představuje homogenní strukturu. To znamená, že nedochází k významným jasovým fluktuacím, a tak náhlé změny jasové stupnice často indikují patologický nález. Pro ohodnocení jednotlivých regionů z globálního pohledu celé multiregionální segmentační metodologie je využíváno Kapurovy entropie [156]. V základním principu Kapurova metoda maximalizuje entropii segmentovaného histogramu. Tato metrika se jeví jako vhodná pro regiony či oblasti, kde jednotlivé hodnoty jsou úzce koncentrovány kolem střední hodnoty a nevykazují podstatnější fluktulace, reprezentované deviativními hodnotami. Toto kritérium je dobře aplikovatelné pro modelování artikulární chrupavky. Z hlediska manifestace artikulární chrupavky na MR platí, že signál MR je pro fyziologickou artikulární chrupavku homogenní, tudíž nevykazuje žádné významné fluktulace. Z tohoto pohledu se předpokládá, že jasové

spektrum je fokusované bez výraznějších variabilit. Tento fakt lze doložit intervalovými odhady střední hodnoty, které reprezentují konečné intervaly, které jsou velice úzce fokusované. V takovéto konfiguraci se dá předpokládat, že pixely náležící do takového regionu budou disponovat vysokou úrovní pravděpodobnosti, a tak vysokou mírou entropie. Obecněji platí, pokud je konkrétní objekt ostře rozlišitelný od svého pozadí, potom histogram monochromatického obrazu bude klasifikován tak, že krajní prahy budou dány v údolí histogramu, které je charakteristické nízkou hodnotou pravděpodobnostní funkce. Pro jednotlivé regiony, které jsou definovány prahy segmentačního modelu: t_1, t_2, \dots, t_m je příspěvek Kapurovy entropie definován jako:

$$H_0 = - \sum_{i=0}^{t_1-1} \frac{p_i}{\omega_0} \ln \left(\frac{p_i}{\omega_0} \right), \omega_0 = \sum_{i=0}^{t_1-1} p_i \quad (4.16)$$

$$H_1 = - \sum_{i=t_1}^{t_2-1} \frac{p_i}{\omega_1} \ln \left(\frac{p_i}{\omega_1} \right), \omega_1 = \sum_{i=t_1}^{t_2-1} p_i \quad (4.17)$$

$$H_j = - \sum_{i=t_j}^{t_{j+1}-1} \frac{p_i}{\omega_j} \ln \left(\frac{p_i}{\omega_j} \right), \omega_j = \sum_{i=t_j}^{t_{j+1}-1} p_i \quad (4.18)$$

$$H_m = - \sum_{i=t_m}^{L-1} \frac{p_i}{\omega_m} \ln \left(\frac{p_i}{\omega_m} \right), \omega_m = \sum_{i=t_m}^{L-1} p_i \quad (4.19)$$

Tímto způsobem je multiregionální prahování konfigurováno jako m-dimenzionální optimalizační problém. Na základě kritéria maximalizace je definována fitness funkce ohodnocující každé přípustné řešení multiregionální segmentace s cílem maximalizace entropie:

$$fit_i = \arg \max \left(\sum_{k=0}^m H_k \right) \quad (4.20)$$

kde fit_i reprezentuje fitness funkci i-tého řešení v rámci genetického algoritmu. Kvalitnější řešení je tedy definováno na základě vyšší hodnoty fitness funkce.

4.3.8 Testování optimalizace distribuce fuzzy množin

Navržené schéma optimalizační procedury se opírá o inicializační populaci řešení X_i . Tento inicializační parametr je klíčový pro efekt optimalizační procedury. V rámci testování je využita inicializační populace 150 řešení a maximální počet iterací 100, při limitu výběru ($L_v = 10$). Následující tabulka dokládá porovnání výsledků ABC optimalizace pro 6 segmentačních tříd. Testování bylo provedeno na 5 obrazových záznamech. Každý záznam byl testován 15 krát. V rámci testování je hodnocena nejlepší (best), nejhorší hodnota (worst) fitness funkce, průměr (mean), medián (median) a směrodatná odchylka (SD). Výsledky jsou sumarizovány v tabulce 4.

Tabulka 4 Komparace výsledků ABC optimalizace.


Testovací obraz	Počet tříd	fit_{best}	fit_{worst}	fit_{median}	fit_{mean}	fit_{SD}
1	6	21.43	21.11	21.43	21.41	0.11
2	6	22.65	22.14	22.33	22.29	0.14
3	6	22.44	21.99	22.12	22.11	0.12
4	6	22.12	21.44	21.99	21.97	0.11
5	6	21.99	21.54	21.68	21.72	0.21

Následující tabulka 5 srovnává výpočetní náročnost jasové klasifikace, která je řízená ABC algoritmem na stejných obrazových záznamech, ale variabilním počtu pixelů. V rámci této komparace se ukazuje, že velikost obrazové matice má nezanedbatelný vliv na efektivitu segmentačního procesu v kontextu počítačové náročnosti.

Tabulka 5 Výpočetní náročnost ABC optimalizace.


Testovací obraz [px]	Pořadí	Počet tříd	Výpočetní náročnost [s]
(800x800)	1	6	8.92
	2	6	10.54
	3	6	10.12
(300x300)	1	6	9.91
	2	6	9.11
	3	6	8.59
(150x150)	1	6	5.45
	2	6	5.22
	3	6	6.12

Následující výstup (Obr. 68) ukazuje typické průběhy nejlepších hodnot fitness funkce v závislosti na jednotlivých iteracích (1-100) pro 5 testovaných obrazů ((a)-(e)). Je zřetelné, že tato funkční závislost vykazuje z hlediska funkční monotónie neklesající charakter. Rovněž se dá dedukovat, že pro vyšší počet iterací je funkce stabilizována. Z tohoto důvodu je volen maximální počet 100 iterací, neboť dle prováděných experimentů, větší počet iterací nadměrně počítačově zatěžuje celý segmentační proces, a zároveň nevede k výraznějšímu posunu z hlediska hodnoty fitness funkce.




Obrázek 68 Typický průběh fitness funkce pro 100 inicializačních řešení ABC algoritmu. Zdroj: vlastní

Podstatným výstupem jasové segmentační procedury na základě fuzzy prahování je grafický model diferencující jednotlivé tkáně dle jasové stupnice. Z hlediska extrakce artikulární chrupavky lze modelovat proces přiřazení každého pixelu v obraze artikulární chrupavky na základě arteficiální barevené mapy, kontrastně diferencující pixely, mající maximální stupeň členství 1 – jednoznačná indikace fyziologické chrupavky až po pixely, mající stupeň členství 0 – jednoznačná eliminace pixelů z oblasti fyziologické chrupavky (Obr. 69). Je zřejmé, že artikulární chrupavka, která je zobrazována se silnějším signálem z MR, je v segmentačním modelu dobře rozlišitelná (žlutá kontura), na druhou stranu artikulární chrupavka nepředstavuje čistě homogenní prostředí, a tak některé její lokace jsou doprovázeny slabším kontrastem vůči okolí, který je způsoben slabším MR signálem. Tyto lokace nejsou jednoznačně klasifikovány ani do, ani mimo model fyziologické chrupavky, dle síly signálu nabývají stupně členství z intervalu (0;1). V tomto bodu se projevuje nedostatečnost segmentační procedury na základě jasu. Jinými slovy je nezbytné, aby metoda byla doplněna procedurou, beroucí v úvahu prostorové relace pixelů s cílem relevantnější aproximace lokací chrupavky, mající slabší úroveň MR signálu.




Obrázek 69 (a) Nativní RoI obrazová MR data artikulární chrupavky obsahující počínající ztrátu chrupavky a (b) segmentační model fyziologické chrupavky na základě arteficiální barevné mapy, indikující příslušný stupeň členství. Zdroj: vlastní



Obrázek 70 (a) Normalizovaný histogram RoI (Obr. 69) a (b) aproximace na základě 6 fuzzy členských funkcí. Zdroj: vlastní

Důležitým výstupem je klasifikace obrazové mapy do jednotlivých fuzzy množin (Obr. 71). Tento klasifikační proces poukazuje na stupeň přiřazení pixelů k jednotlivým tkáním. Z hlediska oblasti zájmu je důležitá artikulární chrupavka. Výstupy a) - f) reprezentují segmentační množiny 1 - 6 segmentační procedury. Je evidentní, že tvrdé tkáně (kosti) jsou klasifikovány v množině 1. Tato posloupnost segmentačních modelů vykazuje největší obsah artikulární chrupavky v segmentačních třídách 5 a 6. Avšak třídy 3 a 4 indikují hranové body, které mají značnou přidruženost k artikulární chrupavce. Z těchto faktů vyplývá, že jednoznačnost klasifikace fyziologické artikulární chrupavky je dosti omezena nehomogenitami jejího povrchu, v tomto důsledku distribuce MR signálu není uniformní. [A.17]



Obrázek 71 Posloupnost dílčích segmentačních modelů artikulární chrupavky na základě 6 segmentačních množin, reprezentovaných výstupy a) – f). Zdroj: vlastní

4.3.9 Prostorová segmentace pixelů (agregace)

4.3.9.1 Podstata agregační procedury

Ze základního úhlu pohledu je možné tvrdit, že účelem agregace je simultánní využívání variabilních částí informace, poskytované variabilními zdroji, aby bylo možné přejít k relevantnímu závěru či rozhodnutí. Hlavním elementem agregace jsou tzv. agregační operátory, které lze definovat jako matematické objekty, které zaujmají funkci redukce množiny čísel do unikátní reprezentace či významného čísla. [153]

4.3.9.2 Základní definice

Agregační problém obsahuje v procesu agregace n -tici objektů, náležejících do dané množiny v rámci jednoduchého objektu. V případě matematického agregačního operátoru této množiny je pracováno s reálnými čísly. V podstatě je agregační operátor reprezentován jednoduchou funkcí, přiřazující reálné číslo y jakékoliv n -tici reálných čísel (x_1, x_2, \dots, x_n) . Obecná agregační funkce je tedy definována následujícím způsobem:

$$y = agg(x_1, x_2, \dots, x_n) \quad (4.21)$$

Na příslušný lokální agregát by přirozeně měly být uloženy jisté podmínky, aby bylo možné zavést zdůvodnitelný název agregačního operátoru. Několik autorů definovalo fundamentální podmínky, definující agregační operátory. Důležitý je fakt, že tyto základní definice nejsou kompatibilní.

Autoři Mesiar a Komorníková navrhli množinu fundamentálních vlastností, které seskupují všechny precedentní definice pod slabší podmínky. Agregace je definována jako funkce: $\cup_{n \in \mathbb{N}} [0,1]^n \rightarrow [0,1]$, splňující:

- Identita unární operace: $Aggreg(x) = x$.

- Hraniční podmínky: $Aggreg(0, \dots, 0) = 0$ a $ggreg(1, \dots, 1) = 1$.
- Neklesající podmínka: $Aggreg(x_1, \dots, x_n) \leq Aggreg(y_1, \dots, y_n)$, jestliže
- $(x_1, \dots, x_n) \leq (y_1, \dots, y_n)$.

Podmínky se jeví jako rekurentní pro všechny navrhované definice agregačních operátorů. V další podkapitole je uveden přehled vlastností, které mohou být očekávatelné u agregačních operátorů. [152, 153]

4.3.9.3 Vlastnosti agregačních operátorů

Hraniční podmínky

V případě vymezení chování operátoru v nejlepším a nejhorším případě se očekává, že agregační operátor splňuje následující podmínky:

$$agg(0, 0, \dots, 0) = 0 \quad (4.22)$$

$$agg(1, 1, \dots, 1) = 1 \quad (4.23)$$

Podmínka (4.22) znamená, že v případě, když dostaneme pouze chybná nebo neuspokojivá kritéria, totální agregace musí být rovněž chybná. Na druhou stranu na základě podmínky (4.23), když dostaneme správné nebo kompletně uspokojivé kritérium, poté musí být totální agregace kompletně správná či uspokojivá.

Byly navrženy extenze těchto základních podmínek. Například autoři Mayor a Trillias navrhuji fundamentální podmínku pro agregační operátor na základě následujících vztahů:

$$\forall x \in [0, 1] \quad agg(x, 0) = agg(1, 0) \cdot x \quad (4.24)$$

$$\forall x \in [0, 1] \quad agg(x, 1) = (1 - agg(1, 0)) \cdot x + agg(1, 0) \quad (4.25)$$

Vztah (4.24) vyžaduje, aby hodnota $agg(x, 0)$ byla váženým aritmetickým průměrem x a 0. Stejně $agg(x, 1)$ je váženým aritmetickým průměrem x a 1 (4.25). Tyto dvě podmínky omezují trošku více skupinu agregačních operátorů.

Monotónnost (neklesající)

Očekává se, že pokud argument roste, finální agregát rovněž roste (nebo alespoň neklesá).

$$y_i \geq x_i \rightarrow agg(x_1, \dots, y_i, \dots, x_n) \geq agg(x_1, \dots, x_i, \dots, x_n) \quad (4.26)$$

Kontinuita

Funkce agg je kontinuální vzhledem ke každé z jejich proměnných. Tato vlastnost je garancí jisté robustnosti pro jistou konzistentnost a pro nechaotické chování.

Asociativnost

Zajímavou vlastností je schopnost agregovat tzv. soubory. Očekává se, volba souborů nemá vliv na výsledek. Tato vlastnost může být popsána na základě tří argumentů:

$$agg(x_1, x_2, x_3) = agg(agg(x_1, x_2), x_3) = agg(x_1, agg(x_2, x_3)) \quad (4.27)$$

Tato vlastnost může být rovněž důležitá v případě, jestliže operátor je definován pouze pro dva elementy, poté asociativnost umožňuje rozšíření definice pro n argumentů bez víceznačnosti.

Symetrie

Tato vlastnost je rovněž známá jako komutativnost nebo anonymita. Pořadí argumentů nemá vliv na výsledek. Tato vlastnost je povinná, když je agregát vytvořen z argumentů, které disponují stejnými vlastnostmi, nebo pocházejí od anonymních expertů či zdrojů. Pro každou permutaci $\sigma \{1, 2, \dots, n\}$ operátor splňuje:

$$agg(x_{\sigma(1)}, x_{\sigma(2)}, \dots, x_{\sigma(n)}) = agg(x_1, x_2, \dots, x_n) \quad (4.28)$$

Bisymetrie

Bisymetrie je vlastnost, asociovaná k agregaci n^2 vstupů operátorů. Pokud jsou zapsány tyto vstupy ve čtvercové matici, poté bisymetrie přenáší fakt, že nezáleží, zda je nejdříve agregován sloupcový vektor a jeho výstup, nebo naopak. Pro binární operátor A , tzn. pro všechny $x_{11}, x_{12}, x_{21}, x_{22}$ platí:

$$A(A(x_{11}, x_{12}), A(x_{21}, x_{22})) = A(A(x_{11}, x_{21}), A(x_{12}, x_{22})) \quad (4.29)$$

Jestliže je operátor komutativní a asociativní, je nutně bisymetrický. Nicméně ani komutativnost a asociativita není implikována bisymetrií.

Absorbující element

Pokud agregační operátor obsahuje absorpční element a , poté může být použit jako tzv. eliminační skóre nebo jako veto (rovněž může být považován za kvalifikační skóre).

$$agg(x_1, \dots, a, \dots, x_n) = a \quad (4.30)$$

Neutrální element

Jestliže agregační operátor obsahuje neutrální element e , může být využit k asociování argumentu, což by nemělo mít žádný vliv na agregaci:

$$agg^{[n]}(x_1, \dots, e, \dots, x_n) = agg^{[n-1]}(x_1, \dots, x_{n-1}) \quad (4.31)$$

Idempotence

Tato vlastnost je také známa jako jednotnost nebo shoda. Pokud je stejná hodnota agregována n krát, očekává se nalezení počáteční hodnoty:

$$agg(x, x, \dots, x) = x \quad (4.32)$$

Kompenzace

Je rovněž známá jako Paretova vlastnost. Očekává se, že výsledek agregace je nižší než největší agregovaný element (maximum), a vyšší než nejmenší agregovaný element (minimum).

$$\min_{i=1}^n(x_i) \leq agg(x_1, x_2, \dots, x_n) \leq \max_{i=1}^n(x_i) \quad (4.33)$$

Vyvažování

Tato vlastnost popisuje chování operátoru, že zvyšuje finální výsledek, jestliže jsou zde argumenty, přecházející do protisměru.

$$\forall t \in [0,1], \forall (x_1, \dots, x_n), \exists x_1, (y_1, \dots, y_m), aby: agg(x_1, \dots, x_n, y_1, \dots, y_m) = t \quad (4.34)$$

Stabilita lineární funkce

Tato vlastnost přenáší stabilitu operátoru s cílem změny měřicí stupnice:

$$agg(r \cdot x_1 + t, r \cdot x_2 + t, \dots, r \cdot x_n + t) = r \cdot (agg(x_1, x_2, \dots, x_n)) + t \quad (4.35)$$

Když $r \geq 0$, potom mluvíme o stabilitě pro kladnou lineární transformaci.

Invariance

Když agregační čísla (x_1, x_2, \dots, x_n) reprezentují měření za jistých kritérií, je možné specifikovat stupnici, kde jsou tato měření provedena. Navíc by se dalo požadovat, aby agregační funkce *agg* respektovala významné relace s ohledem na danou stupnici. Pojem smysluplnosti bývá formalizován v teorii měření jako vlastnost invariance:

Pro jakoukoliv přípustnou transformaci *f*, dostaneme:

$$agg(f(x_1), f(x_2), \dots, f(x_n)) = f(agg(x_1, x_2, \dots, x_n)) \quad (4.36)$$

[150-154]

4.3.10 Lokální agregace segmentační procedury

Samotná segmentační procedura klasifikace pixelů do regionů segmentačního modelu, založená na soft klasifikaci, trpí nedostatkem nižší robustnosti, zejména pro případy, kdy obrazové záznamy jsou zaneseny šumovou složkou. V kontextu tohoto fenoménu vzniká problém nekorektní klasifikace šumových pixelů do regionů, reprezentující segmentované objekty. Předpokládá se, že pixely, představující šumovou složku, disponují signifikantně odlišnou úrovní jasu vzhledem k pixelům, náležícím do příslušného objektu. Tento fakt vede často k nekorektní klasifikaci šumové složky na základě jejího přiřazení do jiné třídy segmentace než je kolenní chrupavka. Touto cestou mohou vznikat v rámci segmentačního modelu chrupavky prázdná místa, indikující nekorektní necelistvost chrupavky a ve výsledku tyto lokace mohou významně zhoršovat efekt a účel segmentace. Lokální agregace má jednoznačný úkol zvážit vliv okolních pixelů, a tím případně modifikovat stupeň členské funkce příslušného pixelu.

Před generováním finální segmentační fáze je potřebné, aby byla brána v úvahu prostorová informace. Tento krok tvoří hlavní příspěvek v rámci celé metodologie. Všestrannost fuzzy logiky umožňuje design mnoha variabilních cest, jak zvážit vliv sousedství ze stupňů $\mu(I(r))$, které jsou definovány v předchozím textu. V následující deskripci je navržen agregát, který je založený na přístupu, který je vhodný pro všeobecné prahování obrazu.


V případě sousedství pixelů $\eta(r)$, které je centrováno v okolí pixelu r , můžeme využít členských hodnot $\mu(I(r))$ všech pixelů v $\eta(r)$ pro lepší klasifikaci obrazu na regiony. Lokální agregát je definován následujícím vztahem:

$$\mu^S(I(r)) = \text{agg}_{s \in \eta(r)}\{\mu(I(s))\} \quad (4.37)$$

kde $\text{agg}\{\cdot\}$ představuje lokální agregát v sousedství pixelů $\eta(r)$. Hlavním účelem této funkce je modifikace originální funkce členství $\mu_l(I(r))$, v případě, kdy lokální informace je brána v úvahu. Důležitou vlastností této operace je fakt, že pracuje v prostoru funkce členství a ne v oblasti nativního, nebo segmentovaného obrazu. Jednotlivé agregáty, které jsou založeny na sousedství pixelů, mohou být definovány a řádně odladěny s cílem dosažení požadovaného výstupu. V následující deskripci jsou uvedeny některé agregáty pro obecný účel prahování obrazu. [138], [143-149, A.17]

4.3.10.1 Význam modifikace členské funkce


Algoritmus soft prahování by mohl být ukončen krokem přiřazení funkce členství každého pixelu do klasifikační třídy na základě maximální hodnoty funkce členství. Tato klasifikace by ovšem jen slabě reflektovala vliv šumových pixelů v objektu. Z hlediska manifestace šumových pixelů se předpokládá, že jejich jasové spektrum je signifikantně odlišné od spektra konkrétního objektu. Z tohoto důvodu šumové pixely značně znehodnocují nativní obrazová data. Jelikož jasové spektrum šumu je odlišné od pozorovaných objektů v obraze, lze předpokládat, že šumové pixely budou rovněž nabývat signifikantně odlišné úrovně členské funkce pro konkrétní oblast od ostatních pixelů v objektu. Následující modelové situace poukazují na varianty, kde se předpokládá, respektive nepředpokládá presence šumových pixelů v klasifikační třídě.



Obrázek 72 Okolí 3x3 analyzovaného pixelu, který je indikován červeně. a) Nepředpokládá se presence šumové složky. b) Analyzovaný středový pixel, představující šumovou složku. Zdroj: vlastní

Je zřejmé, že u situace, kdy nepředpokládáme prezenci šumové složky pro okolí analyzovaného pixelu, jednotlivé pixely budou nabývat vysokých hodnot členské funkce pro konkrétní region. Tato situace je demonstrována na obr. 72 a). V případě presence šumového pixelu se dá předpokládat, že tento pixel nabývá nulové hladiny členské funkce, nebo jeho přidruženost bude velice slabá pro analyzovaný region, neboť disponuje signifikantně odlišnou úrovní jasové stupnice a zřejmě by byl klasifikován do jiného regionu, což by se ve výstupu segmentace projevilo jako artefakt. Tato situace je modelována na obr. 72 b), kde šumový pixel disponuje nulovou hodnotou členské funkce pro analyzovaný region. Tento nepříznivý fenomén je kompenzován využitím lokálního agregátu, který reflektuje prostorovou informaci členské funkce pro jednotlivé pixely. Lokální agregát má za úkol

modifikovat původně přiřazenou hodnotu členské funkce na základě prostorové informace. Jelikož členská funkce šumové složky je signifikantně odlišná od pixelů analyzovaného regionu, měl by být využit operátor, který je robustní vůči odlehlým pozorováním. Alternativou pro tuto situaci je využití mediánu. Nová hodnota středového pixelu může být kalkulována na základě mediánu z okolních pixelů, což dokládá obr. 73.



Obrázek 73 Kalkulace hodnoty členské funkce na základě mediánu analyzovaného pixelu, který je indikován červeně. a) Nepředpokládá se prezence šumové složky. b) Analyzovaný středový pixel, představující šumovou složku. Zdroj: vlastní

Na základě mediánové operace je evidentní, že hodnota členské funkce pixelu, který je méně variabilní od svého okolí, je jen nepatrně modifikována, a dá se předpokládat, že tato změna nebude mít ve finální klasifikaci zásadní vliv na výsledek segmentace (obr. 73a)). V případě modifikace členské funkce šumového pixelu je dosaženo výrazné změny. Původní šumový pixel disponoval nulovou hodnotou členské funkce pro daný region, po aplikaci mediánové operace, stupeň členství konverguje k centroidu analyzovaného regionu, což je doloženo na obr. 73b).

4.3.10.2 Variantní operátory segmentační procedury

V následujícím textu jsou popsány jednotlivé alternativy lokální agregace, které jsou zahrnuty v rámci soft segmentačního přístupu pro modelování kolenních chrupavek.

Mediánový agregát (MedAg)

Členství každého pixelu v $\eta(r)$ je agregováno na základě využití mediánového operátoru. Formulace agregátu *MedAg* je dána následující syntaxí:

$$\mu_i^s(I(r)) = \text{median}_{s \in \eta(r)} \{\mu(I(s))\} \quad (4.38)$$

Je důležité poznamenat, že sousedství $\eta(r)$ může být orientováno tak, aby bylo možné lépe nalézt struktury v jednom konkrétním směru. Medián reprezentuje prostřední hodnotu v případě, kdy data jsou uspořádána do neklesající posloupnosti, která může být formulována následujícím způsobem:

$$x_1 \leq x_2 \leq x_3 \leq \dots \leq x_n$$

Lze tedy říci, že medián reprezentuje takovou hodnotu, která leží uprostřed takové posloupnosti. Z tohoto pohledu lze na medián nahlížet jako na robustní parametr polohy, který je invariantní vůči odlehlým pozorováním. Díky své robustnosti má nejvyšší předpoklady využití v rámci lokální agregace, která by neměla být ovlivněna odlehlými hodnotami členských funkcí s cílem maximalizace efektivity segmentační procedury zejména v případech, kdy je registrována prezence šumu, který by

bez tohoto kroku nebyl korektně klasifikován do příslušného regionu, kam lokálně patří. Výpočet mediánu je závislý na faktu, zda je počet lichý či sudý. Pokud je počet vzorků lichý, medián je kalkulován následujícím způsobem:

$$median = \frac{x_{n+1}}{2} \quad (4.39)$$

V případě, kdy posloupnost obsahuje sudý počet hodnot, neexistuje prvek, který by byl přímo uprostřed, a tudíž posloupnost nelze rozdělit na symetrické poloviny. Proto se bere průměr ze dvou prostředních hodnot tak, že výpočet mediánu je dán následujícím vztahem:

$$median = \frac{\frac{x_n}{2} + \frac{x_{n+2}}{2}}{2} \quad (4.40)$$

Průměrový agregát (AvAg)

Tento agregát definuje průměrování každé členské funkce na základě následující formulace:

$$\mu_i^s(I(r)) = \sum_{r_i \in \eta(r)} \omega_i \cdot \mu_l(I(r_i)) \quad (4.41)$$

Kde ω_i představují váhy zvažovaných pixelů. Jednou z možných definicí může být čtvercové uniformní sousedství, aby platilo:

$$\omega_i = 1/|\eta(r)| \quad (4.42)$$

Kde $|\eta(r)|$ představuje modul zvažovaného sousedství. Při využití *PTS* funkce pouze dva elementy $\mu_l(I)$ nabývají nenulových hodnot, tedy průměrování s vysokou mírou redukuje hodnoty těchto izolovaných pixelů, zatímco uchovává hodnoty homogenních oblastí.

Iterativní průměrová agregace (IterAg)

Iterativní procedura je zaměřena na efektivnější nalezení struktur. Tato procedura průměruje prostor členských funkcí. Poněvadž musí být brán v úvahu kompromis mezi nalezením a vyhlazením struktury, musí být definováno následující okno:

$$h = \begin{pmatrix} 0 & 0.5 & 0 \\ 0.5 & 1 & 0.5 \\ 0 & 0.5 & 0 \end{pmatrix}$$

$$[\mu_l(I(r))]_{t+1} = [\mu_l(I(r))]_t * h \quad (4.43)$$

Kde * označuje prostorovou konvoluci a parametr $t = 0, \dots, T$ označuje počet iterací. Finální krok této procedury je dán následující formulací:

$$\mu_i^s(I(r)) = [\mu_l(I(r))]_T \quad (4.44)$$

Metoda absolutního maxima (AbMax)

Členství každého pixelu v $\eta(r)$ je agregováno na základě využití operátoru maxima:

$$\mu_l^s(I(r)) = \max_{s \in \eta(r)} (\mu_l(I(s))) \quad (4.45)$$

[138, 144, A.5, A.7, A.8, A.10]

4.3.10.3 Implementace lokální agregace

Lokální agregace je implementována ve struktuře čtvercové matice, rozměru $n \times n$, která je iteračně generována na obrazové ploše. Agregace probíhá v prostoru fuzzy členských funkcí napříč jednotlivými obrazovými regiony. Stěžejním předpokladem efektu lokální agregace je modifikace stupně členské funkce příslušného pixelu, který je signifikantně odlišný od ostatních pixelů v masce. Lokální agregace je implementována na základě obrazové konvoluce. Jednotlivé části fuzzy prostoru členských funkcí v rámci příslušného regionu jsou iteračně násobeny tzv. konvolučním jádrem. Toto konvoluční jádro je postupně posouváno v rámci prostoru příslušného regionu. Pro každou iteraci konvolučního jádra je kalkulován příslušný lokální agregát pro pixel, ležící ve středu masky. Z tohoto důvodu je výhradně využíváno čtvercových masek s lichým počtem pixelů (3x3, 5x5, atd.). [A.17, A.21]

4.3.11 Segmentace obrazu

Posledním krokem metodologie je kalkulace finálně segmentovaného obrazu na základě modifikovaných členských funkcí. V tomto finálním kroku je využito operátoru maxima, který je dán následujícím vyjádřením:

$$M(r) = \arg \max_l \{\mu_l^s(I(r))\} \quad (4.46)$$

[144]

4.3.12 Kvantitativní komparace a testování

Tato sekce je věnována kvantitativní komparaci navrhovaného segmentačního algoritmu vůči vybraným regionálním segmentačním metodám a testováním algoritmu pro variabilní nastavení počtu segmentačních množin.

V prvním kroku je řešena komparativní analýza soft prahovací metodologie s některými dobře známými segmentačními přístupy. K této úloze jsou zvoleny klasické algoritmy, algoritmy na bázi fuzzy přístupu a rovněž metody, beroucí v úvahu prostorovou informaci. Tyto metody jsou považovány za dostatečně reprezentativní z hlediska state-of-art prahovacích technik.

- *Otsu* prahovací metoda v binární variantě (2 regiony) a její rozšíření pro N regionů.
- *Fuzzy C means (FCM)*: segmentace je dána na základě metody shlukování. Algoritmus generuje shluky objektů do c částí, pokouší se nalézt těžiště přirozených shluků v datech. K tomuto úkolu se využívá minimalizace vnitřně shlukové variance na základě chybové funkce. Nezbytným parametrem metody je inicializační volba těžišť.
- Iterativní prahovací segmentace (*ITS*) byla původně zamýšlena pro segmentaci velmi zašuměných obrazových dat. Inicializační práh je iteračně přizpůsoben na základě lokální informace, výsledný obraz je méně senzitivní vůči šumu.

- Segmentace založená na maximální prostorové pravděpodobnosti (*MASP*) je rovněž zamýšlena k využití v oblasti zašuměných obrazových dat. Metoda vykonává segmentaci zahrnující lokální prostorovou informaci. Pravděpodobnost náležení pixelu do konkrétní třídy v rámci prostorových omezení je definována jako prostorová pravděpodobnost.
- Prostorové fuzzy shlukování (*S-FCM*) překonává problémy standardní metody *FCM* v případech prezenze šumu a artefaktů. Modifikovaná verze této metody využívá level-set algoritmus, optimalizující efekt segmentace.
- Prahování obrazu využívající typ II fuzzy množin (*FT-II*) kalkuluje globální práh na základě minimalizace nové metriky, zvané ultrafuzziness. Je považován práh jako typ II fuzzy množiny. Metoda generuje pouze dva výstupní regiony.

Navrhovaná metodologie soft prahování je původně zamýšlena pro využití v oblasti dat zanesených šumem a pro případy, kdy hrany specifikující kolenní chrupavku nejsou ostře vymezeny. Z tohoto důvodu je provedena komparativní analýza přístupu jak pro nativní obrazové výstupy kolenní oblasti z MR, tak pro stejné výstupy, kde je superponován Gaussovský šum ($\sigma = 30$) a multiplikativní šum (Rayleigh noise). Následující skalární metriky jsou využity pro komparativní analýzu:

- *Rand index (RI)*: jedná se o měření podobnosti mezi dvěma obrazovými výstupy shlukování. Parametr *RI* porovnává kompatibilitu přiřazení mezi páry elementů ve dvou shlucích kalkulací zlomku korektně klasifikovaných (respektive špatně klasifikovaných) elementů vůči všem elementům. Pro dva shluky C_1 a C_2 je parametr *RI* definován jako:

$$RI(C_1, C_2) = \frac{2(n_{11} + n_{00})}{N(N - 1)} \quad (4.47)$$

kde N je totální počet bodů, n_{11} označuje počet párů, které jsou ve stejném shluku ve C_1 a C_2 a n_{00} je počet párů, které jsou v rozdílných shlucích. *RI* nabývá hodnot 0-1, kde 0 indikuje, že dva obrazy si kompletně neodpovídají na žádném páru bodů a 1 indikuje, že data jsou exaktně stejná.

- *Variace informace (VI)*: tento parametr měří vzdálenost mezi dvěma segmentacemi ve smyslu jejich průměrné podmiňovací entropie, která je dána:

$$VI(C_1, C_2) = \mathcal{H}(C_1) + \mathcal{H}(C_2) - 2I(C_1, C_2) \quad (4.48)$$

kde $\mathcal{H}(C_i)$ představuje entropii asociovanou se shlukem C_i a I je vzájemná informace mezi zhlukováním C_1 a C_2 .

- Překrytí segmentace S_1 segmentací S_2 je definováno jako:

$$C(S_2 \rightarrow S_1) = \frac{1}{N} \sum_{R_1 \in S_1} |R_1| \max_{R_2 \in S_2} O(R_1, R_2) \quad (4.49)$$

kde $O(R_1, R_2)$ je překrytí mezi regiony R_1 a R_2 definované jako:


$$O(R_1, R_2) = \frac{|R_1 \cap R_2|}{|R_1 \cup R_2|} \quad (4.50)$$

Využíváme dvou komplementárních deskriptorů $C(S_2 \rightarrow S_1)$ a $C(S_1 \rightarrow S_2)$. [138]


Tabulka 6 Komparativní analýza metody soft prahování s vybranými metodami.

		MedAg	AvAg	FCM	Otsu-N	S-FCM	MASP
RI	Nat.	0.791	0.728	0.723	0.723	0.739	0.698
	Gauss.	0.697	0.669	0.601	0.683	0.681	0.667
	Mult.	0.681	0.697	0.665	0.654	0.612	0.571
VI	Nat.	2.956	2.611	2.979	2.675	2.922	3.459
	Gauss.	3.122	3.788	3.312	3.367	3.122	3.998
	Mult.	3.233	3.811	3.711	3.568	3.679	3.799
$C(S_2 \rightarrow S_1)$	Nat.	0.366	0.343	0.354	0.343	0.371	0.219
	Gauss.	0.298	0.322	0.291	0.262	0.312	0.242
	Mult.	0.345	0.289	0.271	0.233	0.327	0.236
$C(S_1 \rightarrow S_2)$	Nat.	0.498	0.448	0.455	0.411	0.467	0.341
	Gauss.	0.499	0.295	0.353	0.412	0.399	0.277
	Mult.	0.391	0.365	0.343	0.367	0.389	0.311

V rámci testování jsou testovány dvě alternativy metody soft prahování, které se liší v aplikaci lokální agregace. V rámci testování je komparován mediánový agregát (*MedAg*) a průměrový agregát (*AvAg*). Testování je generováno na vzorku 30 záznamů kolenní oblasti MR 3T. V tabulce 6 jsou zaznamenány nejlepší výsledky jednotlivých metod. Z hlediska parametru *RI* a překrytí segmentace, čím je vyšší hodnota parametru, tím je test úspěšnější, zatímco pro parametr *VI*, čím je hodnota testu nižší, tím je test úspěšnější. Výsledky v širší míře ukazují, že metoda soft prahování vykazuje nejlepší výsledky z hlediska analyzovaných parametrů. Důležitým parametrem je rovněž robustnost z hlediska přítomnosti šumu v obrazových záznamech. Z hlediska samotné komparace mezi lokálními agregáty se jako efektivnější a robustnější jeví mediánová agregace (*MedAg*), která je následně i využívána v rámci geneze modelu chrupavek.




Obrázek 74 Komparace segmentačních výstupů na RoI 250x200 pixelů s analyzovaným počtem segmentačních množin: 3 (a), 5 (b), 7 (c) a 10 (d). Zdroj: vlastní




Obrázek 75 Komparace segmentačních výstupů na RoI 500x400 pixelů s analyzovaným počtem segmentačních množin: 3 (a), 5 (b), 7 (c) a 10 (d). Zdroj: vlastní

Segmentační výstupy pro dílčí velikosti obrazové matice disponují odlišnou kvalitou obrazové mapy, kde u neinterpolované oblasti je kontura chrupavky téměř neměnná bez ohledu na volbu počtu segmentačních množin. Silnější rozdíly jsou patrné pro větší obrazovou matici, kde je aplikována interpolační procedura. Pro volbu tří segmentačních množin (Obr. 75 (a)) je chrupavka (žlutá kontura) kontinuální i v místě, kde je předpoklad ztráty chrupavky, což je klasifikováno jako nedostatek segmentační procedury. U následujících výstupů již chrupavka nedisponuje kontinuálním průběhem, je zde patrné, že chrupavka je rozdělena na dvě části – zde je evidentní, že chrupavka chybí. Důležitým faktem je rovněž diferenciací dvou kolenních chrupavek a eliminace a rovněž diferenciací barevné mapy v místech, kde chrupavka není.


Dalším důležitým testovacím kritériem je robustnost metody vůči aditivnímu šumu. V rámci tohoto testování je řešena shodná analýza s předchozími případy, t.j. pro počet segmentačních množin 10 a velikost obrazové matice 500x400 pixelů. Analýza robustnosti řešení byla provedena pro Gaussovský, multiplikativní a Salt and Pepper šum.




Obrázek 76 RoI se superponovaným šumem Salt and Pepper s variantní šumovou hustotou (d): (a) $d=0.05$, (b) $d=0.1$, $d=0.5$ a (d) $d=0.8$. Zdroj: vlastní




Obrázek 77 Výstup segmentace se superponovaným šumem Salt and Pepper s variantní šumovou hustotou (d): (a) $d=0.05$, (b) $d=0.1$, $d=0.5$ a (d) $d=0.8$. Zdroj: vlastní




Obrázek 78 ROI se superponovaným Gaussovským šumem se střední hodnotou (μ) a variancí (σ): (a) $\mu = 0, \sigma = 0.01$, (b) $\mu = 0, \sigma = 0.08$, (c) $\mu = 0, \sigma = 0.1$ a (d) $\mu = 0, \sigma = 0.8$. Zdroj: vlastní



Obrázek 79 Výstup segmentace se superponovaným Gaussovským šumem se střední hodnotou (μ) a variancí (σ): (a) $\mu = 0, \sigma = 0.01$, (b) $\mu = 0, \sigma = 0.08$, (c) $\mu = 0, \sigma = 0.1$ a (d) $\mu = 0, \sigma = 0.8$. Zdroj: vlastní




Obrázek 80 ROI se superponovaným multiplikativním šumem se střední hodnotou (μ) a variancí (v): (a) $\mu = 0, v = 0.01$, (b) $\mu = 0, v = 0.08$, (c) $\mu = 0, v = 0.1$ a (d) $\mu = 0, v = 0.8$. Zdroj: vlastní



**Obrázek 81 Výstup segmentace se superponovaným multiplikativním šumem se střední hodnotou (μ) a variancí (v): (a) $\mu = 0, v = 0.01$, (b) $\mu = 0, \sigma = 0.08$, (c) $\mu = 0, \sigma = 0.1$ a (d) $\mu = 0, \sigma = 0.8$.
Zdroj: vlastní**


Metoda soft prahování je testována v závislosti na variabilním zdroji šumové složky pro různá nastavení, od jemnějších narušení obrazové informace, až k případům, kde obrazová informace téměř zcela chybí. Na základě komparace je zřejmé, že metoda vykazuje nejrobustnější výsledky pro aplikaci multiplikativního šumu. V tomto případě jsou v největší míře zachovány tvarové parametry segmentovaných kontur. Naopak je patrné, že metoda je senzitivnější k prezenci Gaussovského šumu. V tomto případě se rovněž dá mluvit o zachování hladkosti segmentovaných kontur, nicméně hlavním pozorovaným faktem jsou diskontinuity v morfologické struktuře chrupavky. V případě Gaussovského šumu dochází ke spojení chrupavky, což výrazně ovlivňuje efekt segmentační procedury.

Posledním testovaným parametrem segmentační procedury je velikost mediánového okna ve fázi agregační procedury. Segmentační procedura generuje multiregionální model v závislosti na nastaveném počtu segmentačních tříd. Tento parametr určuje rozložení regionů v první fázi segmentace. Druhou klíčovou fází procedury je agregační krok, který dle typu zvolené agregace agreguje pixely do klasifikačních tříd na základě prostorových závislostí. To jinými slovy znamená, že jistý pixel, který byl původně klasifikován do segmentační množiny, může být finálně klasifikován do množiny jiné v závislosti na prostorové distribuci členských funkcí ostatních pixelů. Agregační procedura může modifikovat originálně přiřazenou členskou funkci pixelu za jinou dle typu agregační procedury. Na základě komparativní analýzy (Tab. 6) se jako nejrobustnější jeví mediánová agregační procedura. Obr. 82 dokládá komparaci agregační procedury pro čtvercovou velikost agregačního okna: 3, 7, 15 a 23.



Obrázek 82 Výsledek komparativní analýzy mediánové agregační procedury. Testovací RoI 500x400 pixelů (a), mediánový agregát s maskou: 3x3 (b), 7x7 (c), 15x15 (d) a 23x23 (e). Zdroj: vlastní

Agregační krok vykazuje variabilní hladkost segmentovaných kontur v závislosti na velikosti agregačního okna. Pro velikost agregačního okna 3x3 segmentační procedura vykazuje v oblasti kostní oblasti (modrá kontura) relativně vyšší obsah šumové složky, projevující se drobnými shluky menšího počtu pixelů (Obr. 82 (b)), naproti tomu pro nejvyšší velikost mediánového okna (23x23) jsou tyto artefakty téměř kompletně eliminovány (Obr. 82 (e)). Tento fenomén se rovněž projevuje na hladkosti kontury kolenní chrupavky. Nicméně pro vyšší rozměry agregačního okna je v některých lokacích kolenní chrupavka ztenčena, což podhodnocuje efekt segmentační procedury (Obr. 83).



Obrázek 83 Výstup mediánové agregační procedury s velikostí okna 23x23, kde ztenčení kontury chrupavky je indikováno červeným RoI. Zdroj: vlastní

5 Geneze a analýza modelu

Jak již bylo zmíněno v předchozím textu, stěžejní oblastí zájmu v kontextu obrazové analýzy kolenních chrupavek je automatická lokalizace chrupavky, identifikace a konsekventní extrakce oblastí, které korespondují s chondromalacií, tedy s místy, kde dochází ke ztrátě chrupavky. Tento patologický jev je klinicky klasifikován do čtyř stádií, v závislosti na stádiu onemocnění. Z hlediska zpracování obrazu je nejzajímavější první (rané) stádium, když patologické změny nejsou čistě identifikovatelné pouhým okem. Pozdější stádia jsou běžně doprovázeny výraznou změnou jasové stupnice, a tak jsou úspěšně klasifikovatelná pouhým okem, bez nutnosti metod zpracování obrazu. Stěžejní oblasti zájmu jsou tedy lokace, kde se z klinického hlediska předpokládá výskyt raných patologických změn.


Navrhovanou metodiku multiregionálního modelu, využívající soft prahování, je z tohoto úhlu pohledu možné klasifikovat do převážně poloautomatických metod. Automaticnost metody je zde odvozena na základě inicializačního kroku, kde uživatel definuje oblast zájmu chrupavky, která má být analyzována. Tento krok přispívá k fokusaci artikulární chrupavky na významně větší obrazovou plochu, než je tomu v nativním MR záznamu. Stěžejní nevýhodou zobrazování artikulárních chrupavek je jejich malá obrazová plocha, neboť při jejich vyšetření je snímána kolenní oblast.

Na rozdíl od mnoha segmentačních metod, uváděných v recentní literatuře, metoda multiregionální segmentace, založená na principu soft prahování, umožňuje diferenciaci jednotlivých tkání s cílem extrakce oblasti artikulárních chrupavek. Metody, které jsou založeny na tvarové analýze, čili popisují objekt v obraze na základě jeho hranic, umožňují většinou pouze prostou lokalizaci konkrétního objektu. Navržené řešení je primárně orientováno dvěma základními směry, a sice umožňuje automatickou lokalizaci artikulární chrupavky a analýzu povrchu, která je klíčová pro identifikaci míst, kde chrupavka ztrácí svou celistvost. Významným benefitem této metodiky je rovněž robustnost vůči šumu, který je v určité míře spjat s každou medicínskou zobrazovací metodou. Šumová složka je kompenzována na základě lokální agregace, která představuje finální krok segmentačního modelu.

K modelování kolenních chrupavek je přistoupeno ve dvou modalitách. První alternativou, která byla již zmíněna, je selekce oblasti zájmu, na který je následně aplikována segmentační procedura, která má diferencovat oblast chrupavky od obrazového pozadí v rámci segmentačního modelu. Zřejmou nevýhodou tohoto přístupu je manuální omezení obrazové oblasti, která je podrobena obrazové analýze, takže je analyzována pouze část struktury chrupavky. Na druhou stranu tento přístup významně fokusuje oblast chrupavky, která je v nativních záznamech relativně malá. Druhým přístupem je analýza celkového nativního obrazového záznamu kolenní oblasti. Celkový obrazový záznam kolenní oblasti je komplexní a obsahuje více struktur, které nesouvisí s chrupavkou.

5.1 Segmentační model využívající selekci oblasti zájmu


Testování modelu je provedeno pro variantní MR sekvence. V následujícím textu jsou analyzovány výstupy z dílčích sekvencí v konfrontaci s výstupy modelu. Z klinického hlediska je důležitá dekompozice kolenní oblasti na dílčí anatomické struktury a jejich manifestace v nativních klinických datech. Chondromalacie je často klinicky hodnocena v rámci PD sekvencí. Na následujícím výstupu (Obr. 84) je typický příklad počínajících změn kolenní chrupavky (počínající ztráta chrupavky). Problémem je, že počínající změny jsou často obtížně klasifikovatelné, neboť jejich manifestace je slabá. Kolenní chrupavka je považována za fyziologickou v případech, kdy jasový profil v rámci její plochy je stálý bez výraznějších fluktuací. V případě, když dochází k více či méně pozorovatelným změnám jasové stupnice, dá se předpokládat, že morfologická struktura chrupavky je porušena.



Obrázek 84 Nativní obrazová data z PD sekvence s vyznačeným RoI, kde je předpoklad porušení celistvosti artikulární chrupavky (a), RoI bez interpolace (b) a RoI s kubickou interpolací (c).


Zdroj: vlastní

Z pohledu extrakce patologických extrakcí je důležitá jejich manifestace. V prvním kroku procedury je provedena extrakce oblasti zájmu (RoI), fokusující vybranou oblast zájmu. Tento krok je důležitý z hlediska kvality a hladkosti segmentační mapy. V případě aplikování prostého RoI (Obr. 84. (b)) je fokusována relativně malá obrazová plocha. Tento fenomén vede k rozmazání obrazové informace, což negativně ovlivňuje kvalitu segmentačních výstupů. Alternativou může být využití kubické interpolační procedury, která má za úkol optimalizovat obrazovou informaci a zachovat ostrost hranových oblastí (Obr. 84. (c)). Rovněž je důležitý stupeň interpolace. V případě aplikování vyššího stupně interpolace pravděpodobně dosáhneme detailnější obrazové informace, ale za cenu vyšší počítačové náročnosti celého procesu. V rámci analýzy modelu byla rovněž testována alternativa bez využití segmentační procedury, která se jevila jako nedostatečná, neboť segmentované kontury nevykazují hladký průběh (Obr. 85).



Obrázek 85 Výstup segmentační procedury soft prahování (6 klasifikačních tříd) bez využití interpolační techniky. Zdroj: vlastní

Je evidentní, že segmentační model je zatížen nepřesností, neboť kontury nevykazují hladký průběh. S přihlédnutím k faktu, že plošný model kolenní chrupavky by mohl být konsekventně použit k modelování buď plošných, nebo volumetrických parametrů chrupavky, je tato skutečnost dosti omezující. Následující výstup vykazuje výstup segmentační procedury při využití kubické interpolace.



Obrázek 86 Výstup segmentační procedury soft prahování (6 klasifikačních tříd) s využitím kubické interpolace. Zdroj: vlastní

Segmentační algoritmus na bázi soft prahování jednoznačně diferencuje jednotlivé struktury v obrazových datech do ostrých množin. Z hlediska řešení modelu artikulárních chrupavek je stěžejní oblast indikovaná červeně. Dva laloky reprezentují strukturu chrupavky, kde je chrupavka celistvá a nevykazuje známky poškození. Mezi jednotlivými komponentami chrupavky je viditelné přerušení, které indikuje chondromalacii, která je z nativních dat obtížně pozorovatelná. Finální částí modelu je extrakce oblasti kolenní chrupavky, aby ostatní struktury byly potlačeny. Tento úkol je možné řešit manuální cestou, když je dáno, jakou hodnotou je kódována oblast chrupavky, potom ostatní struktury mohou být nulovány. Tato eliminační metoda může být popsána následujícím výrazem:

$$I_L < g(x) < I_H \quad (5.1)$$


Kde $g(x)$ reprezentuje matici segmentovaného obrazu, I_L a I_H indikují hranice segmentačních tříd, reprezentujících oblast chrupavky.

5.1.1 Extrakce artikulární chrupavky

Následující výstupy (Obr. 87 a Obr. 88) ukazují testování komplexního řešení detekce kolenní chrupavky na základě soft prahování. Na obrazová data je aplikováno okno (RoI) s interpolací. Následně je aplikována segmentační procedura, generující segmentační model. V tomto konkrétním přístupu je využito 4 klasifikačních tříd (chrupavka je manifestována červeně). V posledním kroku je provedena extrakce kolenní chrupavky, což představuje finální koncept modelu. Model reflektuje pouze omezenou část chrupavky, kde je z klinického hlediska predispozice osteoartritidy I. stupně, projevující se jen velmi slabou, relativně nezřetelnou změnou jasové stupnice oproti fyziologickému průběhu chrupavky, který je manifestován v jednotném jasovém spektru s jen slabými jasovými fluktuacemi. Tento fakt je standardně hlavním vodítkem, že kolenní chrupavka disponuje nepoškozenou strukturou. Model chrupavky jednoznačně manifestuje oblasti, kde není registrováno poškození (červené laloky), které jsou odděleny mezerou, kde je evidentní, že chrupavka chybí.



Obrázek 87 Nativní MR obrazová data s vyznačeným RoI (vlevo), segmentační výstup (4 klasifikační třídy) (uprostřed) a finální model kolenní chrupavky, reflektující chondromalacii I. stupně, která je obtížně pozorovatelná z nativních záznamů (vpravo). Zdroj: vlastní




Obrázek 88 Nativní MR obrazová data s vyznačeným RoI (vlevo), segmentační výstup (4 klasifikační třídy) (uprostřed) a finální model kolenní chrupavky, reflektující chondromalacii I. stupně, která je obtížně pozorovatelná z nativních záznamů (vpravo). Zdroj: vlastní

Jednou z implementací segmentační procedury je analýza časově inverzních kolenních obrazů, které jsou hodnoceny např. z důvodu prezenze fokálních defektů (Obr. 89), kde se fokální defekt

manifestuje na trochleární drážce. Oblast zájmu (červené RoI) je segmentována s 8 množinami a agregována mediánovým oknem o velikosti 9x9 pixelů. Výsledný model chrupavky (Obr. 90) je zobrazen po její extrakci doplněnou o morfologickou erozi, eliminující drobnější shluky pixelů.




Obrázek 89 Časově inverzní kolenní obraz indikující plně chondrální defekt (šipky) s vyznačeným RoI pro segmentaci (červeně). Zdroj: vlastní




Obrázek 90 Segmentační model (8 klasifikačních tříd) časově inverzního kolenního obrazu po extrakci regionu kolenní chrupavky doplněnou morfologickou erozí, kde chondrální defekt je ostře ohraničen (žlutá kontura) v červeném RoI. Zdroj: vlastní

Následující výstup (Obr. 91 (a)) ilustruje aplikaci segmentační metodologie na sagitální 2D SE obraz. Tento výstup umožňuje lokalizaci chrupavčitého defektu, který je kontrastně vyobrazen již v nativním záznamu (hrot šipek). Segmentační procedura (Obr. 91 (b)) diferencuje oblast části kolenní chrupavky (modré RoI), kde obrazové okolí je potlačeno. Analyzovaný defekt je ostře ohraničen (červené RoI).




Obrázek 91 Nativní data kolenní oblasti, získané na základě 2D SE zobrazování. Nativní obraz poskytuje lepší kontrast mezi povrchem chrupavky, synoviální tekutinou. Vysoký kontrast dobře diferencuje chrupavčítý defekt (hrot šipek), kde modré RoI indikuje oblast zájmu pro segmentaci. Segmentační výstup (8 segmentačních množin) lokalizuje oblast části kolenní chrupavky, chrupavčítý defekt je ostře ohraničen žlutou konturou v červeném RoI (b). Zdroj: vlastní

Jedním z typů morfologického posouzení kolenních chrupavek je technika FLASH. Tato technika je rovněž využitelná pro hodnocení časové změny tloušťky a objemu chrupavky. Fyziologická chrupavka je charakteristická vysokou signálovou intenzitou v rámci FLASH zobrazování, z tohoto důvodu jsou superficiální léze kontrastněji pozorovatelné. Na druhou stranu tyto léze mohou být nekorektně slučovány s defekty chrupavky, např. fisurami. Následující výstup (Obr. 92) ukazuje model kolenní chrupavky reflektující kompletní ztrátu chrupavky mediální oblasti s degenerativními lézemi.




Obrázek 92 T2 vážený obraz s potlačením tuku reflektuje lokace kompletní ztráty chrupavky v mediální tibiofemorální oblasti s degenerativními lézemi v subchondrální kosti (hrot šipky), kde červené RoI indikuje oblast zájmu pro segmentační proceduru (a). Výstup segmentačního modelu kolenní chrupavky reflektující největší signálovou intenzitu (žluté kontury), naopak model detekuje lokace, kde dochází ke ztrátě chrupavky (červené oblasti zájmu), degenerativní léze jsou ostře ohraničeny žlutou konturou v modrém RoI (b). Zdroj: vlastní

Poslední z aplikačních oblastí, kde je soft segmentační algoritmus testován, je MR zobrazování s variabilními silovými poli. Tyto modalitty nejsou běžně klinicky využívány, jsou převážně využívány v oblasti klinického výzkumu. Hlavním benefitem silnějších magnetických polí je kontrastnější zobrazení kolenních chrupavek. Na druhou stranu dochází ke zhoršení magnetické susceptibility v tkáních a obrazy jsou více náchylné k plovoucím artefaktům. Na základě studií, využívající 7.0T MR zobrazování vyplývá, že tato modalita je efektivnější pro zobrazování morfologické stavby kolenní chrupavky, výhodou tohoto zobrazování je dosažení vyššího rozlišení s kratším akvizčním časem oproti 3.0T systémům. Následující výstupy ukazují aplikační možnosti modelování kolenních chrupavek z 3.0T MR (Obr. 93) a z 7.0T MR (Obr. 94). Analyzovaná MR data vykazují v obou případech fyziologickou chrupavku, která je silnějším magnetickým polem reprezentována vyšší úrovní signálu, což vede k lepšímu kontrastu vůči ostatním tkáním. Prvním důležitým pozorovaným faktem je celistvost kolenní chrupavky, která je v segmentačních modelech doprovázena převážně jednotným barevným spektrem (žlutá kontura). Důležitým faktem segmentačního modelu je rovněž robustnost vůči artefaktům, způsobených magnetickým polem. Obrazová data 7.0T MR jsou ovlivněna magnetickou susceptibilitou, tato lokace je indikována hrotem šipek, nicméně tento artefakt je v modelu eliminován.



Obrázek 93 Sagitální 3.0T MR obraz kolenní oblasti zdravého dobrovolníka, nevykazující signifikantní diference v oblasti manifestace kolenní chrupavky (a), segmentační model kolenní chrupavky, identifikující celistvost morfologické struktury (žlutá kontura), model je generován po aplikaci morfologické eroze, eliminující drobnější shluky pixelů (b). Zdroj: vlastní



Obrázek 94 Sagitální 7.0T MR obraz kolenní oblasti zdravého dobrovolníka, nevykazující signifikantní diference v oblasti manifestace kolenní chrupavky, nativní data rovněž vykazují artefakty, způsobené magnetickou susceptibilitou, což je indikováno hrotem šipky (a), segmentační model kolenní chrupavky, identifikující celistvost morfologické struktury (žlutá kontura), model je generován po aplikaci morfologické eroze, eliminující drobnější shluky pixelů (b). Zdroj: vlastní

6 Závěr

V rámci klinické diagnostiky existuje několik konvenčně využívaných metod pro vizualizaci a hodnocení kolenních chrupavek. Zejména se jedná o RTG, UZV a MR. Vzhledem ke svým rozsáhlým možnostem MR zaujímá primární postavení mezi těmito zobrazovacími modalitami, zejména díky vysokému obrazovému rozlišení a kontrastu mezi chrupavkou a ostatními tkáněmi. Navíc vybrané MR sekvence umožňují hodnotit morfológickou strukturu kolenních chrupavek. V tomto ohledu je důležitá selekce fyziologické chrupavky od patologických změn, které narušují strukturu chrupavky a v pozdních stádiích mohou vést k celkové ztrátě chrupavky. Jelikož MR využívá variabilní sekvence, některé konvenčně využitelné pro vizualizaci chrupavek, jiné pouze v oblasti klinického výzkumu, vzniká velké množství variabilních obrazových dat, které jsou více či méně použitelné pro morfológické hodnocení kondice kolenní chrupavky. I přes všechny nesporné výhody MR zobrazování, je aktuální otázkou extrakce informací z obrazových záznamů, které umožňují automatickou deskripci chrupavky. V tomto kontextu je důležitým identifikátorem chrupavky její celistvost, fyziologická struktura a modelování patologických procesů. Tyto informace bývají často pouze subjektivně odhadovány, z čehož vyplývá, že kvalita takovýchto závěrů je silně závislá na subjektivním hodnocení a zkušenostech experta v oblasti radiologie, nebo ortopedie. Na základě těchto faktů je vývoj segmentačních technik zacílených na genezi syntetických modelů kolenních chrupavek stále aktuální.

Z hlediska segmentačních přístupů, které jsou dohledatelné v recentní literatuře, lze segmentační algoritmy a příslušné modely chrupavek klasifikovat do třech skupin v závislosti na míře intervence uživatele na manuální, poloautomatické a automatické. Manuální segmentace je založena na preciznosti a zkušenostech uživatele, neboť kompletně celá metoda je generována uživatelem. Tyto metody jsou stále aktuální v oblasti komparační analýzy, kde slouží jako zlatý standard pro konkrétní segmentační metodu. Poloautomatické metody jsou většinou doprovázeny inicializační fází, která je řízena uživatelem, na rozdíl od automatické segmentace, která pracuje autonomně bez jakékoli intervence. Z recentní literatury vyplývá, že častým problémem segmentace chrupavek je nižší robustnost řešení pro variabilní MR sekvence, disponující variabilní obrazovou kvalitou a reprodukovatelností informací. Důležitým problémem publikovaných segmentačních metod je rovněž pouhá lokalizace oblasti chrupavky z nativního záznamu, bez konsekventní analýzy povrchu a spolehlivé identifikace patologických procesů. Rovněž v mnoha případech není zřejmé, zda segmentační metoda je aplikovatelná jak pro fyziologické, tak pro patologické chrupavky. Tyto závěry vedou k úvaze, že spolehlivý model kolenních chrupavek by měl reflektovat jak lokalizaci chrupavky, tak analýzu její morfológické struktury. Na základě takového modelu je možné stavět rozhodovací proceduru, umožňující klasifikaci fyziologické a patologické struktury chrupavky.

Navrhované řešení pro genezi modelu kolenních chrupavek je založeno na dvoufázové segmentační metodologii, umožňující hrubou lokalizaci oblasti kolenní chrupavky a konsekventní analýzu povrchu chrupavky. Důležitým faktem je, že se jedná o metodologii, a nikoliv o uzavřený algoritmus. To znamená, že v každém kroku je nabízena alternativa, která dle testování na reálných MR datech vykazuje relevantní výsledky. Analýza MR dat je řešena ve dvou rovinách. Je možné provést selekci oblasti zájmu (RoI), kde se odhaduje prevalence patologického nálezu. Model reflektuje parciální část chrupavky, která je diferencována od patologické změny v oblasti barevné syntetické mapy. Nevýhodou tohoto přístupu je aplikace interpolační procedury, optimalizující obrazové

vlastnosti oblasti zájmu, což vede k vyšším výpočetním nárokům celého procesu segmentace. Interpolace rovněž modifikuje originální obrazovou mapu, což může vést ke zkreslenému výsledku. Druhou variantou je analýza celého obrazového záznamu. Výhodou tohoto přístupu je modelování kompletní struktury chrupavky, obvykle za cenu menších geometrických rozměrů.

Multiregionální segmentační model využívá dvou fází klasifikace pixelů. V prvním kroku je aplikována soft prahovací segmentační metodologie modifikovaná konsekventním lokálním agregačním krokem. Stěžejní vlastností této metodologie je, že provádí klasifikaci pixelů na základě jasové a prostorové informace. Jasová klasifikace se opírá o sekvenci fuzzy množin, které specifikují jednotlivé obrazové regiony v rámci multiregionálního segmentačního modelu. Stěžejním problémem tohoto přístupu je optimální distribuce jednotlivých klasifikátorů (fuzzy množin) tak, aby bylo dosaženo maximální korelace mezi příslušným regionem a tkání, která je aproximována touto fuzzy množinou. V rámci této metodologie je využíváno trojúhelníkovitých fuzzy členských funkcí. Těžiště příslušné fuzzy množiny je hledáno na základě optimalizačního řešení, postaveného na bázi genetického algoritmu, využívající zhodnocovací procedury jednotlivých přípustných řešení na základě extrakce příznaků, charakterizující fyziologickou strukturu artikulární chrupavky. Tato jasová klasifikace může následně být modifikována lokální agregací, beroucí v úvahu prostorové relace mezi sousedními pixely. Každý pixel je tedy klasifikován v jasové a prostorové doméně. Tato skutečnost dělá metodu značně senzitivnější vůči šumu a artefaktům, oproti konvenčním technikám založených na ostrém prahování. Výsledný model chrupavky má reflektovat jak geometrické vlastnosti, tak morfologickou strukturu. Robustnost modelu je deklarována na základě aditivních zdrojů obrazového šumu, komparací vůči vybraným segmentačním metodám a rovněž komparativní analýzou vůči alternativní segmentaci, představující jistý druh zlatého standardu.

Proces jasové klasifikace je řízen genetickým *ABC* algoritmem. Vstupní populace je dána hrubou segmentací histogramu pomocí metody K-means. Tato metoda generuje shluky pixelů, které jsou klasifikovány dle minimální vzdálenosti k těžišti příslušné třídy. Tato těžiště jsou brána jako inicializační řešení *ABC* algoritmu. Další přípustná řešení jsou vytvářena generátorem náhodných čísel se střední hodnotou zmiňovaných těžišť. Těžiště segmentační množiny, reprezentující fyziologickou chrupavku, je generováno na základě ideálního modelu chrupavky, dle mediánového odhadu. Jednotlivá přípustná řešení selekce histogramu jsou ohodnocována pomocí fitness funkce, beroucí v úvahu Kapurovu entropii segmentačního modelu.

Druhou částí segmentační metodologie je lokální agregace, beroucí v úvahu prostorové relace pixelů. Již zmiňované hranové a šumové pixely mohou být korektněji klasifikovány na základě jejich okolí. Tento problém může být řešen na základě klouzavého okna, kalkuluující medián z příslušného okolí pixelu, který je popsán pomocí posloupnosti členských hodnot fuzzy trojúhelníkovitých funkcí. Typickou situací je šumový pixel, mající signifikantně odlišnou hodnotu funkce členství v příslušné fuzzy členské funkci, než okolní pixely. Dle jasové klasifikace by byl zcela jistě klasifikován do jiné segmentační třídy i přesto, že leží uvnitř množiny, kam patří. Agregační procedura kalkuluje medián z takového okolí pixelů, následně je středový pixel modifikován. Důležitým faktem je robustnost této procedury vůči pixelům, které mají homogennější okolí z hlediska hodnoty členské funkce. Medián z úzce fokusovaných hodnot zpravidla signifikantně nemění jejich charakter, a tak je tato procedura výrazně senzitivní k homogennímu okolí průběhu členských funkcí. Šum a hranové pixely představují z hlediska segmentace významnou kapitolu segmentační procedury, proto je lokální agregace důležitá. Z tohoto hlediska byla metoda testována rovněž pro značně znehodnocená data na základě Salt and

Pepper, Gaussovského a multiplikativního šumu s variabilními parametry vůči vybraným multiregionálním segmentačním modelům. Na základě kvantitativního testování se jeví jako nejrobustnější alternativa mediánová agregace. Na základě uvedených faktů lze konstatovat, že předložená segmentační metoda je značně rezistivní vůči obrazovému šumu, který je v určité hladině přítomen v jakýchkoliv medicínských datech, a významně ovlivňuje kvalitu extrakce klinických informací z medicínských obrazů. V tomto ohledu je důležitá velikost filtračního okna, definující okolí analyzovaného pixelu. V rámci testování metodologie byly analyzovány čtvercové velikosti: 3, 7, 15, 23. Je vidět, že zvyšující se velikost okna efektivně eliminuje drobné shluky pixelů a slouží jako jistá filtrace segmentačního modelu a rovněž způsobuje vyhlazení kontur segmentovaných objektů, na druhou stranu v některých místech způsobuje deformaci plochy chrupavky, vedoucí k jejím celkovému podhodnocení.

Segmentační model byl testován na vzorku MR dat, kde dochází k počínajícím patologickým změnám, které jsou obtížněji klasifikovatelné lidským okem. MR zajišťuje vizualizaci artikulární chrupavky, vykazující fyziologické rysy v homogenním jasovém spektru. Naopak patologické změny způsobují útlum MR signálu, což vede k jasovým diferencím v závislosti na stádiu patologického progresu. Počínající patologické ztráty chrupavky se projevují jen malou změnou jasové stupnice, a tak v nativních záznamech jsou často špatně identifikovatelné. Fuzzy prahování s lokální agregací umožňuje generovat model morfologické struktury chrupavky, který je senzitivní k těmto změnám. Model byl testován na vybraných oblastech zájmu, kde se předpokládá prezence počínajících degenerativních změn. Model generuje celistvou strukturu pro chrupavku, vykazující fyziologický průběh potvrzený radiologickými experty a přerušení chrupavky v místech, kde dochází k počínající degeneraci. Tímto způsobem je jednoznačně určena fyziologická chrupavka a počínající patologie.

Z hlediska klasifikace segmentační metodologie se jedná o poloautomatickou segmentační proceduru, vyžadující určitý stupeň lidské interakce ve fázi extrakce kontury chrupavky. Ovšem v rámci testování zejména na vzorku MR PD sekvencí byla fyziologická chrupavka spolehlivě identifikována v poslední segmentační třídě, při použití 6 tříd. Tyto obrazové MR jsou klinicky běžně využívány pro diagnostiku, proto je oblast zájmu směřována zejména sem. Na druhou stranu MR umožňuje využití variabilních sekvencí, umožňující selektivní vizualizaci komponent, jako je např. zobrazování sodíku, rovněž důležitým parametrem obrazu je konkrétní magnetická indukce, která ovlivňuje kvalitu zobrazování. V rámci testování byly analyzovány dvě modalities 1.5 a 3T. Tyto aspekty mohou ovlivnit jasovou manifestaci artikulární chrupavky v rámci segmentačního modelu. Z hlediska budoucího rozšíření této problematiky by mohlo být přínosné doplnit segmentační model o tvarový deskriptor, který by automaticky klasifikoval třídu, nebo třídy modelu, nejlépe reflektující oblast chrupavky z alternativních MR sekvencí.

Literatura

- [1] A. Štouračová. Možnosti zobrazení artikulární chrupavky včetně volumetrických měření. Brno, 2011. Disertační práce. *Lékařská fakulta Masarykovy University v Brně*.
- [2] C.L. Junqueira, J. Carneiro, R.O. Kelley. Základy histologie, *Vydání 1., Praha: H+H, 2002, 502 s.*
- [3] P. Višňa, R. Hart a kol., Chrupavka kolena, Vyd. 1. Praha: *Maxdorf, 2006, 208 s.*
- [4] J. Bartoníček, J. Heřt. Základy klinické anatomie pohybového aparátu, Vyd.1. Praha: *Maxdorf, 2004. 256 s.*
- [5] R. Čihák. Anatomie 1. Vydání 2. *Grada: Praha, 2001: 293-306.*
- [6] J.P. Fulkerson. Patellofemoral Foundation [online]. 2009 [cit. 2016-02-11]. Disorders of the patellofemoral joint. Dostupné z WWW: <http://www.patellofemoral.org/>.
- [7] K. Pavelka, J. Rovenský. Klinická revmatologie. Vyd. 1. Praha: *Galen, 2003.*
- [8] D.W. Stoler et al. Magnetic resonance imaging in orthopaedics and sports medicine, 1st.Ed. Baltimore: *Lippincott Williams and Wilkins, 2007, 1039.*
- [9] A.B. Jandaghi, M. Mardani-Kivi, A. Mirbolook, M.K. Emami-Meybodi, S. Mohammadzadeh, M. Farahmand. Comparison of indirect MR arthrography with conventional MRI in the diagnosis of knee pathologies in patients with knee pain (2016) *Trauma Monthly*, 21 (2), art. no. e20718.
- [10] C.R. Antholz, J.J. Cherian, R.K. Elmallah, J.J. Jauregui, T.P. Pierce, M.A. Mont. Selective Patellar Resurfacing: A Literature Review (2015) *Surgical technology international*, 26, pp. 355-360.
- [11] C. Nuttall, B.A. Winters. Understanding Anterior Knee Pain: Patellofemoral Pain Syndrome (2015) *Journal for Nurse Practitioners*, 11 (10), pp. 1032-1035.
- [12] N.G. Lasanianos, N.K. Kanakaris. *Chondral lesions* (2015) *Trauma and Orthopaedic Classifications: A Comprehensive Overview*, pp. 501-504.
- [13] F. Ruiz Santiago, R. Pozuelo Calvo, J. Almansa López, L. Guzmán Álvarez, M.D.T. Castellano García. T2 mapping in patellar chondromalacia (2014) *European Journal of Radiology*, 83 (6), pp. 984-988.
- [14] N. Caplan, D.F. Kader. The etiology of chondromalacia patellae (2014) *Classic Papers in Orthopaedics*, pp. 185-187.
- [15] E. Hong, M.C. Kraft. Evaluating Anterior Knee Pain (2014) *Medical Clinics of North America*, 98 (4), pp. 697-717.

- [16] S. Thomas, D. Rupiper, G.S. Stacy. Imaging of the patellofemoral joint (2014) *Clinics in Sports Medicine*, 33 (3), pp. 413-436.
- [17] U. Koller, S. Apprich, S. Domayer, R. Windhager, S. Trattnig. Magnetic resonance mapping of the rim of articular cartilage defects of the patella (2014) *International Orthopaedics*, 38 (1), pp. 67-72.
- [18] H.K. Kok, J. Donnellan, D. Ryan, W.C. Torreggiani. Correlation between subcutaneous knee fat thickness and chondromalacia patellae on magnetic resonance imaging of the knee (2013) *Canadian Association of Radiologists Journal*, 64 (3), pp. 182-186.
- [19] J.E. Budoff, R.P. Nirschl. Injured or arthritic knees: Evaluating patellofemoral and tibiofemoral articulation (2013) *Consultant*, 53 (7), pp. 507-511.
- [20] C. Mazzola, D. Mantovani. Patellofemoral malalignment and chondral damage: Current concepts (2013) *Joints*, 1 (2), pp. 27-33.
- [21] D.M. Biko, A.L. Miller, V. Ho-Fung, D. Jaramillo. MRI of congenital and developmental abnormalities of the knee (2012) *Clinical Radiology*, 67 (12), pp. 1198-1206.
- [22] J. Beran. Small injuries of peripheral skeleton in X-ray image [Drobné úrazy periferného pohybového aparátu v RTG obraze] (2012) *Ceska Radiologie*, 66 (4), pp. 347-353.
- [23] S.T. Duncan, M.S. Khazzam, J.M. Burnham, K.P. Spindler, W.R. Dunn, R.W. Wright. Sensitivity of standing radiographs to detect knee arthritis: A systematic review of Level I studies (2015) *Arthroscopy - Journal of Arthroscopic and Related Surgery*, 31 (2), pp. 321-328.
- [24] J.L. Drape, A. Chevrot, D. Godefroy, A.M. Dupon, F. Gires. CT scans and arthro-CT scans (1996) *Bailliere's Clinical Rheumatology*, 10 (4), pp. 615-634.
- [25] S. Wang. X-ray investigation of chondromalacia patellae (1988) *Zhonghua fang she xue za zhi Chinese journal of radiology*, 22 (6), pp. 337-340.
- [26] J.L. Howie. Computed tomography in osteochondritis dissecans of the patella (1985) *Canadian Association of Radiologists Journal*, 36 (3), pp. 197-199.
- [27] M. Reiser, P.M. Karp, P. Bennett. Diagnosis of chondromalacia patellae using CT arthrography (1992) *European Journal of Radiology*, 2 (3), pp. 181-186.
- [28] Y. Wu, S. Krishnan, R.M. Rangayyan. Computer-aided diagnosis of knee-joint disorders via vibroarthrographic signal analysis: A review (2010) *Critical Reviews in Biomedical Engineering*, 38 (2), pp. 201-224.
- [29] H.I. Keen, P.G. Conaghan. Ultrasonography in Osteoarthritis, *Radiologic Clinics of North America*, 47: 581-594.
- [30] H. Kellner, H. Liess, W.G. Zoller. 3D-ultrasound of soft tissues and joints, *Bildgebung* 1994; 61(2): 130-34.

- [31] W.M. Oo, M.T. Bo. Role of ultrasonography in knee osteoarthritis (2016) *Journal of Clinical Rheumatology*, 22 (6), pp. 324-329.
- [32] S. Tuna, N. Balcı, L. Özçakar. The relationship between femoral cartilage thickness and muscle strength in knee osteoarthritis (2016) *Clinical Rheumatology*, 35 (8), pp. 2073-2077.
- [33] S. Eroglu, E.E. Inal, M. Eroglu, S. Oruc, A.M. Ulasli, H. Cevik, S. Demirci, O. Solak, U. Dundar, H. Toktas, M. Yaman. Ultrasound detection of knee joint degeneration in patients with multiple sclerosis (2016) *Journal of Rehabilitation Medicine*, 48 (7), pp. 604-608.
- [34] S. Ohashi, I. Ohnishi, H. Oka, T. Matsumoto, M. Bessho, K. Nakamura, S. Tanaka. The effect of cartilage degeneration on ultrasound speed in human articular cartilage (2016) *Modern Rheumatology*, 26 (3), pp. 426-434.
- [35] J.M. Koski, A. Kamel, P. Waris, V. Waris, I. Tarkiainen, E. Karvanen, M. Szkudlarek, S.Z. Aydin, E. Alasaarela, W. Schmidt, E. De Miguel, P. Mandl, E. Filippucci, H. Ziswiler, L. Terslev, K. Áts, R. Kurucz, E. Naredo, P. Balint, A. Iagnocco, S. Lepojärvi, A. Elseoud, M. Fouda, S. Saarakkala. Atlas-based knee osteophyte assessment with ultrasonography and radiography: Relationship to arthroscopic degeneration of articular cartilage (2016) *Scandinavian Journal of Rheumatology*, 45 (2), pp. 158-164.
- [36] L. Wang, Q. Chen, P. Tong, L. Xia, H. Jin. Progress on the early diagnosis of knee osteoarthritis (2016) *Zhongguo gu shang = China journal of orthopaedics and traumatology*, 29 (3), pp. 288-291.
- [37] P. Penttilä, J. Liukkonen, A. Joukainen, T. Virén, J.S. Jurvelin, J. Töyräs, H. Kröger. Diagnosis of Knee Osteochondral Lesions With Ultrasound Imaging (2015) *Arthroscopy Techniques*, 4 (5), pp. e429-e433.
- [38] D. Burstein, M. Gray. New MRI techniques for imaging cartilage, *Journal of Bone Joint Surgery Am*; 2003, 85: 70–77.
- [39] X. Li, E.T. Han, C.B. Ma, T.M. Link, D.C. Newitt, S. Majumdar. In vivo 3T spiral imaging based multi-slice T(1rho) mapping of knee cartilage in osteoarthritis. *Magn Reson Med*. 2005; 54: 929-36.
- [40] X. Li, C.B. Ma, T.M. Link et al. In vivo T1rho and T2 mapping of articular cartilage in osteoarthritis of the knee using 3 T MRI, *Osteoarthr. Cartilage* 2007; 15: 789-97.
- [41] T.M. Link, R. Stahl, K. Woertler. Cartilage imaging: motivation, techniques, current and future significance, *Eur Radiology*, 2007; 17: 1135–1146.
- [42] D.T. Felson. Osteoarthritis of the knee. *N Engl J Med* 2006;354(8):841–848.
- [43] G.E. Gold, C.A. Chen, S. Koo, B.A. Hargreaves, N.K. Bangerter. Recent advances in MRI of articular cartilage. *AJR Am J Roentgenol* 2009;193(3): 628–638.

- [44] D. Burstein, M. Gray, T. Mosher, B. Dardzinski. Measures of molecular composition and structure in osteoarthritis. *Radiol Clin North Am* 2009;47(4): 675–686.
- [45] S. Trattng, S. Domayer, G.W. Welsch, T. Mosher, F. Eckstein. MR imaging of cartilage and its repair in the knee: a review. *Eur Radiol* 2009;19(7):1582–1594.
- [46] T.M. Link, R. Stahl, K. Woertler. Cartilage imaging: motivation, techniques, current and future significance. *Eur Radiol* 2007;17(5):1135–1146.
- [47] C. Black, C. Clar, R. Henderson et al. The clinical effectiveness of glucosamine and chondroitin supplements in slowing or arresting progression of osteoarthritis of the knee: a systematic review and economic evaluation. *Health Technol Assess* 2009; 13(52):1–148.
- [48] K.P. Jungius, M.R. Schmid, M. Zanetti, J. Hodler, P. Koch, C.W. Pfirrmann. Cartilaginous defects of the femorotibial joint: accuracy of coronal short inversion time inversion-recovery MR sequence. *Radiology* 2006;240(2):482–488.
- [49] R. Kijowski, D.G. Blankenbaker, K.W. Davis, K. Shinki, L.D. Kaplan, A.A. De Smet. Comparison of 1.5- and 3.0-T MR imaging for evaluating the articular cartilage of the knee joint. *Radiology* 2009;250(3): 839–848.
- [50] C.G. Peterfy, A. Guermazi, S. Zaim et al. Whole-Organ Magnetic Resonance Imaging Score (WORMS) of the knee in osteoarthritis. *Osteoarthritis Cartilage* 2004;12(3):177–190.
- [51] D.J. Hunter, G.H. Lo, D. Gale, A.J. Grainger, A. Guermazi, P.G. Conaghan. The reliability of a new scoring system for knee osteoarthritis MRI and the validity of bone marrow lesion assessment: BLOKS (Boston Leeds Osteoarthritis Knee Score). *Ann Rheum Dis* 2008;67(2):206–211.
- [52] P.R. Kornaat, R.Y. Ceulemans, H.M. Kroon et al. MRI assessment of knee osteoarthritis: Knee Osteoarthritis Scoring System (KOSS) inter-observer and intra-observer reproducibility of a compartment based scoring system. *Skeletal Radiol* 2005;34(2):95–102.
- [53] D.G. Disler, T.R. McCauley, C.G. Kelman et al. Fatsuppressed three-dimensional spoiled gradient-echo MR imaging of hyaline cartilage defects in the knee: comparison with standard MR imaging and arthroscopy. *AJR Am J Roentgenol* 1996;167(1):127–132.
- [54] M.D. Crema, F.W. Roemer, M.D. Marra, D. Burstein, G.E. Gold, F. Eckstein, T. Baum, T.J. Mosher, J.A. Carrino, A. Guermazi. Articular cartilage in the knee: current MR imaging techniques and applications in clinical practice and research. (2011) *Radiographics : a review publication of the Radiological Society of North America, Inc*, 31 (1), pp. 37-61.
- [55] F.W. Roemer, A. Guermazi, J.A. Lynch et al. Short tau inversion recovery and proton density-weighted fat suppressed sequences for the evaluation of osteoarthritis of the knee with a 1.0 T dedicated extremity MRI: development of a time-efficient sequence protocol. *Eur Radiol* 2005;15(5):978–987.

- [56] A. Mohr, M. Priebe, B. Taouli, J. Grimm, M. Heller, J. Brossmann. Selective water excitation for faster MR imaging of articular cartilage defects: initial clinical results. *Eur Radiol* 2003;13(4):686–689.
- [57] H. Graichej, V. Springer, T. Flaman et al. Validation of high-resolution water-excitation magnetic resonance imaging for quantitative assessment of thin cartilage layers. *Osteoarthritis Cartilage* 2000;8(2): 106–114.
- [58] S.R. Duc, C.W. Pfirrmann, M.R. Schmid et al. Articular cartilage defects detected with 3D waterexcitation true FISP: prospective comparison with sequences commonly used for knee imaging. *Radiology* 2007;245(1):216–223.
- [59] J.A. Vallotton, R.A. Meuli, P.F. Leyvraz, M. Landry. Comparison between magnetic resonance imaging and arthroscopy in the diagnosis of patellar cartilage lesions: a prospective study. *Knee Surg Sports Traumatol Arthrosc* 1995;3(3):157–162.
- [60] D.M. Freeman, G. Bergman, G. Glover. Short TE MR microscopy: accurate measurement and zonal differentiation of normal hyaline cartilage. *Magn Reson Med* 1997;38(1):72–81.
- [61] R. Kijowski, K.W. Davis, M.A. Woods et al. Knee joint: comprehensive assessment with 3D isotropic resolution fast spin-echo MR imaging—diagnostic performance compared with that of conventional MR imaging at 3.0 T. *Radiology* 2009;252(2):486–495.
- [62] F.W. Roemer, Y. Zhang, J. Niu et al. Tibiofemoral joint osteoarthritis: risk factors for MR-depicted fast cartilage loss over a 30-month period in the multicenter osteoarthritis study. *Radiology* 2009;252(3): 772–780.
- [63] V. Bobic. ICRS articular cartilage imaging committee. ICRS MR imaging protocol for knee articular cartilage. Zollikon, Switzerland: *International Cartilage Repair Society*, 2000; 12.
- [64] F.W. Roemer, D.J. Hunter, A. Guermazi. MRI-based semiquantitative assessment of subchondral bone marrow lesions in osteoarthritis research. *Osteoarthritis Cartilage* 2009;17(3):414–415; author reply 416–417.
- [65] R. Kijowski, D.G. Blankenbaker, J.L. Klaers, K. Shinki, A.A. De Smet, W.F. Block. Vastly undersampled isotropic projection steady-state free precession imaging of the knee: diagnostic performance compared with conventional MR. *Radiology* 2009;251(1):185–194.
- [66] O. Ristow, L. Steinbach, G. Sabo et al. Isotropic 3D fast spin-echo imaging versus standard 2D imaging at 3.0 T of the knee: image quality and diagnostic performance. *Eur Radiol* 2009;19(5):1263–1272.
- [67] D.G. Disler, T.R. McCauley, C.R. Wirth, M.D. Fuchs. Detection of knee hyaline cartilage defects using fat-suppressed three-dimensional spoiled gradientecho MR imaging: comparison with standard MR imaging and correlation with arthroscopy. *AJR Am J Roentgenol* 1995;165(2):377–382.

- [68] F. Eckstein, A. Guermazi, F.W. Roemer. Quantitative MR imaging of cartilage and trabecular bone in osteoarthritis. *Radiol Clin North Am* 2009;47(4): 655–673.
- [69] M.D. Crema, A. Guermazi, L. Li et al. The association of prevalent medial meniscal pathology with cartilage loss in the medial tibiofemoral compartment over a 2-year period. *Osteoarthritis Cartilage* 2010;18(3):336–343.
- [70] D.B. Siepmann, J. McGovern, J.H. Brittain, S.B. Reeder. High-resolution 3D cartilage imaging with IDEAL SPGR at 3 T. *AJR Am J Roentgenol* 2007; 189(6):1510–1515.
- [71] W. Wirth, M. Nevitt, M.P. Hellio Le Graverand et al. Sensitivity to change of cartilage morphometry using coronal FLASH, sagittal DESS, and coronal MPR DESS protocols: comparative data from the Osteoarthritis Initiative (OAI). *Osteoarthritis Cartilage* 2010;18(4):547–554.
- [72] C. Glaser, B.J. Tins, C.G. Trumm, J.B. Richardson, M.F. Reiser, I.W. McCall. Quantitative 3D MR evaluation of autologous chondrocyte implantation in the knee: feasibility and initial results. *Osteoarthritis Cartilage* 2007;15(7):798–807.
- [73] B.A. Hargreaves, G.E. Gold, P.K. Lang et al. MR imaging of articular cartilage using driven equilibrium. *Magn Reson Med* 1999;42(4):695–703.
- [74] G.E. Gold, S.E. Fuller, B.A. Hargreaves, K.J. Stevens, C.F. Beaulieu. Driven equilibrium magnetic resonance imaging of articular cartilage: initial clinical experience. *J Magn Reson Imaging* 2005;21(4): 476–481.
- [75] R. Radlbauer, F. Lomoschitz, E. Salomonowitz, K.E. Eberhardt, A. Stadlbauer. MR imaging of the knee: improvement of signal and contrast efficiency of T1-weighted turbo spin echo sequences by applying a driven equilibrium (DRIVE) pulse. *Eur J Radiol* 2010;75(2):e82–e87.
- [76] S.R. Duc, C.W. Pfirrmann, P.P. Koch, M. Zanetti, J. Hodler. Internal knee derangement assessed with 3-minute three-dimensional isovoxel true FISP MR sequence: preliminary study. *Radiology* 2008;246 (2):526–535.
- [77] S.S. Vasawala, J.M. Pauly, D.G. Nishimura, G.E. Gold. MR imaging of knee cartilage with FEMR. *Skeletal Radiol* 2002;31(10):574–580.
- [78] F.K. Schaefer, B. Kurz, P.J. Schaefer et al. Accuracy and precision in the detection of articular cartilage lesions using magnetic resonance imaging at 1.5 Tesla in an in vitro study with orthopedic and histopathologic correlation. *Acta Radiol* 2007;48(10): 1131–1137.
- [79] C. Liess, S. Lüsse, N. Karger, M. Heller, C.C. Glüer. Detection of changes in cartilage water content using MRI T2-mapping in vivo. *Osteoarthritis Cartilage* 2002;10(12):907–913.
- [80] T.J. Mosher, H. Smith, B.J. Dardzinski, V.J. Schmithorst, M.B. Smith. MR imaging and T2 mapping of femoral cartilage: in vivo determination of the magic angle effect. *AJR Am J Roentgenol* 2001;177(3):665–669.

- [81] T.C. Dunn, Y. Lu, H. Jin, M.D. Ries, S. Majumdar. T2 relaxation time of cartilage at MR imaging: comparison with severity of knee osteoarthritis. *Radiology* 2004;232(2):592–598.
- [82] M.F. Koff, K.K. Amrami, K.R. Kaufman. Clinical evaluation of T2 values of patellar cartilage in patients with osteoarthritis. *Osteoarthritis Cartilage* 2007;15 (2):198–204.
- [83] C. Stehling, H. Liebl, R. Krug et al. Patellar cartilage: T2 values and morphologic abnormalities at 3.0-T MR imaging in relation to physical activity in asymptomatic subjects from the osteoarthritis initiative. *Radiology* 2010;254(2):509–520.
- [84] G.H. Welsch, T.C. Mamsch, S.E. Domayer et al. Cartilage T2 assessment at 3-T MR imaging: in vivo differentiation of normal hyaline cartilage from reparative tissue after two cartilage repair procedures—initial experience. *Radiology* 2008;247(1):154–161.
- [85] A. Williams, L. Sharma, C.A. McKenzie, P.V. Prasad, D. Burstein. Delayed gadolinium-enhanced magnetic resonance imaging of cartilage in knee osteoarthritis: findings at different radiographic stages of disease and relationship to malalignment. *Arthritis Rheum* 2005;52(11):3528–3535.
- [86] C.J. Tiderius, J. Svensson, P. Leander, T. Ola, L. Dahlberg. dGEMRIC (delayed gadolinium-enhanced MRI of cartilage) indicates adaptive capacity of human knee cartilage. *Magn Reson Med* 2004;51(2): 286–290.
- [87] A. Anandacoomarasamy, B.M. Giuffre, S. Leibman et al. Delayed gadolinium-enhanced magnetic resonance imaging of cartilage: clinical associations in obese adults. *J Rheumatol* 2009;36(5):1056–1062.
- [88] A. Bashir, M.L. Gray, J. Hartke, D. Burstein. Nondestructive imaging of human cartilage glycosaminoglycan concentration by MRI. *Magn Reson Med* 1999;41(5):857–865.
- [89] A. Watanabe, Y. Wada, T. Obata et al. Delayed gadolinium-enhanced MR to determine glycosaminoglycan concentration in reparative cartilage after autologous chondrocyte implantation: preliminary results. *Radiology* 2006;239(1):201–208.
- [90] U. Duvvuri, S.R. Charagundla, S.B. Kudchodkar et al. Human knee: in vivo T1(rho)-weighted MR imaging at 1.5 T—preliminary experience. *Radiology* 2001;220(3):822–826.
- [91] R. Stahl, A. Luke, X. Li et al. T1rho, T2 and focal knee cartilage abnormalities in physically active and sedentary healthy subjects versus early OA patients: a 3.0-Tesla MRI study. *Eur Radiol* 2009;19(1): 132–143.
- [92] V. Mlynárik, S. Trattig, M. Huber, A. Zembsch, H. Imhof. The role of relaxation times in monitoring proteoglycan depletion in articular cartilage. *J Magn Reson Imaging* 1999;10(4):497–502.
- [93] A. Borthakur, E.M. Shapiro, J. Beers, S. Kudchodkar, J.B. Kneeland, R. Reddy. Sensitivity of MRI to proteoglycan depletion in cartilage: comparison of sodium and proton MRI. *Osteoarthritis Cartilage* 2000;8(4):288–293.

- [94] L. Wang, Y. Wu, G. Chang et al. Rapid isotropic 3D sodium MRI of the knee joint in vivo at 7T. *J Magn Reson Imaging* 2009;30(3):606–614.
- [95] A.J. Wheaton, A. Borthakur, E.M. Shapiro et al. Proteoglycan loss in human knee cartilage: quantitation with sodium MR imaging—feasibility study. *Radiology* 2004;231(3):900–905.
- [96] D. Burstein, M.L. Gray, A.L. Hartman, R. Gipe, B.D. Foy. Diffusion of small solutes in cartilage as measured by nuclear magnetic resonance (NMR) spectroscopy and imaging. *J Orthop Res* 1993;11(4): 465–478.
- [97] T.C. Mamsch, M.I. Menzel, G.H. Welsch et al. Steady-state diffusion imaging for MR in-vivo evaluation of reparative cartilage after matrix-associated autologous chondrocyte transplantation at 3 tesla: preliminary results. *Eur J Radiol* 2008;65(1):72–79.
- [98] B. Kladny, K. Glückert, B. Swoboda, W. Beyer, G. Weseloh. Comparison of low-field (0.2 Tesla) and high-field (1.5 Tesla) magnetic resonance imaging of the knee joint. *Arch Orthop Trauma Surg* 1995;114 (5):281–286.
- [99] M.D. Crema, F.W. Roemer, Y. Zhu et al. Subchondral cystlike lesions develop longitudinally in areas of bone marrow edema-like lesions in patients with or at risk for knee osteoarthritis: detection with MR imaging—the MOST study. *Radiology* 2010;256(3): 855–862.
- [100] F.W. Roemer, J.A. Lynch, J. Niu et al. A comparison of dedicated 1.0 T extremity MRI vs large-bore 1.5 T MRI for semiquantitative whole organ assessment of osteoarthritis: the MOST study. *Osteoarthritis Cartilage* 2010;18(2):168–174.
- [101] R. Stahl, R. Krug, D.A. Kelley et al. Assessment of cartilage-dedicated sequences at ultra-high-field MRI: comparison of imaging performance and diagnostic confidence between 3.0 and 7.0 T with respect to osteoarthritis-induced changes at the knee joint. *Skeletal Radiol* 2009;38(8):771–783.
- [102] R. Krug, J. Carballido-Gamio, S. Banerjee et al. In vivo bone and cartilage MRI using fully-balanced steady-state free-precession at 7 tesla. *Magn Reson Med* 2007;58(6):1294–1298.
- [103] J. Carballido-Gamio, J. S. Bauer, R. Stahl, K. Lee, S. Krause, T. M. Link, and S. Majumdar. Inter-subject comparison of MRI knee cartilage thickness. *Medical image analysis*, 12(2):120–135, 2008.
- [104] Y. Yin, X. Zhang, R. Williams, X. Wu, D. D. Anderson, and M. Sonka. LOGISMOS|layered optimal graph image segmentation of multiple objects and surfaces: cartilage segmentation in the knee joint. *Medical Imaging, IEEE Transactions on*, 29(12):2023–2037, 2010.
- [105] S. Lee, S. Hyun Park, H. Shim, Il D. Yun, and S. U. Lee. Optimization of local shape and appearance probabilities for segmentation of knee cartilage in 3-D MR images. *Computer Vision and Image Understanding*, 115(12):1710–1720, 2011.

- [106] J. Folkesson, E. B. Dam, O. F. Olsen, P. C. Pettersen, and C. Christiansen. Segmenting articular cartilage automatically using a voxel classification approach. *Medical Imaging, IEEE Transactions on*, 26(1):106{115, 2007.
- [107] F. Cicuttini, A. Forbes, K. Morris, S. Darling, M. Bailey, and S. Stuckey. Gender differences in knee cartilage volume as measured by magnetic resonance imaging. *Osteoarthritis and Cartilage*, 7(3):265{271, 1999.
- [108] M. D. van Leersum, M. E. Schweitzer, F. Gannon, S. Vinitzki, G. Finkel, and D. G. Mitchell. Thickness of patellofemoral articular cartilage as measured on mr imaging: sequence comparison of accuracy, reproducibility, and interobserver variation. *Skeletal radiology*, 24(6):431{435, 1995.
- [109] F. Eckstein, S. Muller, S.C. Faber, K-H Englmeier, M. Reiser, and R. Putz. Side differences of knee joint cartilage volume, thickness, and surface area, and correlation with lower limb dominance an mri-based study. *Osteoarthritis and cartilage*, 10(12):914{921, 2002.
- [110] J. Duryea, G. Neumann, M.H. Brem, W. Koh, F. Noorbakhsh, R.D. Jackson, J. Yu, C.B. Eaton, and P. Lang. Novel fast semi-automated software to segment cartilage for knee MR acquisitions. *Osteoarthritis and cartilage*, 15(5):487{492, 2007.
- [111] H. Shim, S. Chang, C. Tao, J. H. Wang, C. K. Kwoh, and K. T. Bae. Knee cartilage: Efficient and reproducible segmentation on high-spatial-resolution mr images with the semiautomated graph-cut algorithm method 1. *Radiology*, 251(2):548{556, 2009.
- [112] J. Carballido-Gamio, J. S. Bauer, R. Stahl, K. Y. Lee, S. Krause, T. M. Link, and S. Majumdar. Inter-subject comparison of MRI knee cartilage thickness. *Medical image analysis*, 12(2):120{135, 2008.
- [113] J. G. Tamez-Pena, M. BarbuMcInnis, and S. Totterman. Knee cartilage extraction and bone-cartilage interface analysis from 3d mri data sets. In *Medical Imaging 2004*, pages 1774{1784. International Society for Optics and Photonics, 2004.
- [114] A. Sanfeliu and M. L. Cortes. Progress in pattern recognition, *image analysis and applications*. Springer, 2004.
- [115] S. K. War eld, K. H. Zou, and W. M. Wells. Simultaneous truth and performance level estimation (staple): an algorithm for the validation of image segmentation. *Medical Imaging, IEEE Transactions on*, 23(7):903{921, 2004.
- [116] D. E. Dupuy, R. M. Spillane, M. S. Rosol, D. I. Rosenthal, W. E. Palmer, D. W. Burke, and A. E. Rosenberg. Quantification of articular cartilage in the knee with three-dimensional MR imaging. *Academic radiology*, 3(11):919{924, 1996.
- [117] V. Grau, A. Mewes, M. Alcaniz, R. Kikinis, and S. K. Wareld. Improved watershed transform for medical image segmentation using prior information. *Medical Imaging, IEEE Transactions on*, 23(4):447{458, 2004.

- [118] Ch. Lantuejoul and F. Maisonneuve. Geodesic methods in quantitative image analysis. *Patternrecognition*, 17(2):177{187, 1984.
- [119] S. Akhtar, C.L. Poh, and R.I. Kitney. An MRI derived articular cartilage visualization framework. *Osteoarthritis and Cartilage*, 15(9):1070{1085, 2007.
- [120] T. Iranpour-Boroujeni, A. Watanabe, R. Bashtar, H. Yoshioka, and J. Duryea. Quantification of cartilage loss in local regions of knee joints using semi-automated segmentation software: analysis of longitudinal data from the osteoarthritis initiative (oai). *Osteoarthritis and Cartilage*, 19(3):309{314, 2011.
- [121] M.H. Brem, P.K. Lang, G. Neumann, P.M. Schlechtweg, E. Schneider, R. Jackson, J. Yu, C.B. Eaton, F.F. Hennig, H. Yoshioka et al. Magnetic resonance image segmentation using semi-automated software for quantification of knee articular cartilage|initial evaluation of a technique for paired scans. *Skeletal radiology*, 38(5):505{511, 2009.
- [122] L. König, M. Groher, A. Keil, C. Glaser, M. Reiser, N. Navab. Semi-automatic segmentation of the patellar cartilage in MRI (2007) *Informatik aktuell*, pp. 404-408.
- [123] A. X. Falcao, J. K. U. dupa, S. Samarasekera, S. Sharma, B. E. Hirsch, and R. de A. Lotufo. User-steered image segmentation paradigms: Live wire and live lane. *Graphical models and image processing*, 60(4):233{260, 1998.
- [124] K.T. Bae, H. Shim, C. Tao, S. Chang, J.H. Wang, R. Boudreau, and C.K. Kwoh. Intra-and inter- observer reproducibility of volume measurement of knee cartilage segmented from the OAI MR image set using a novel semiautomated segmentation method. *Osteoarthritis and Cartilage*, 17(12):1589{1597, 2009.
- [125] Y. Y. Boykov and M.P. Jolly. Interactive graph cuts for optimal boundary & region segmentation of objects in nd images. In *Computer Vision, 2001. ICCV 2001. Proceedings. Eighth IEEE International Conference on*, volume 1, pages 105{112. IEEE, 2001.
- [126] C. Kaufmann, P. Gravel, B. Godbout, A. Gravel, G. Beaudoin, J. P. Raynauld, J. Martel-Pelletier, J. P. Pelletier, and J. A. de Guise. Computer-aided method for Quantification of cartilage thickness and volume changes using MRI: validation study using a synthetic model. *Biomedical Engineering, IEEE Transactions on*, 50(8):978{988, 2003.
- [127] P. Dodin, J. P. Pelletier, J. Martel-Pelletier, and F. Abram. Automatic human knee cartilage segmentation from 3-D magnetic resonance images. *Biomedical Engineering, IEEE Transactions on*, 57(11):2699{2711, 2010.
- [128] C. Lorenz and J. von Berg. Fast automated object detection by recursive casting of search rays. In *International Congress Series*, volume 1281, pages 230{235. Elsevier, 2005.

- [129] K. Zhang, W. Lu, and P. Marziliano. Automatic knee cartilage segmentation from multi-contrast MR images using support vector machine classification with spatial dependencies. *Magnetic resonance imaging*, 31(10):1731-1743, 2013.
- [130] J. Fripp, S. Crozier, S. K. Wareld, and S. Ourselin. Automatic segmentation and quantitative analysis of the articular cartilages from magnetic resonance images of the knee. *Medical Imaging*, IEEE Transactions on, 29(1):55-64, 2010.
- [131] E. D. Angelini and E. J. Ciaccio. Optimized region merging and edge detection of knee cartilage surfaces from magnetic resonance images. *Annals of biomedical engineering*, 31(3):336-345, 2003.
- [132] J. Fripp, S. Crozier, S. K. Wareld, and S. Ourselin. Automatic segmentation of the bone and extraction of the bone-cartilage interface from magnetic resonance images of the knee. *Physics in Medicine and Biology*, 52(6):1617, 2007.
- [133] S. Kashyap, I. Oguz, M. Sonka. Statistical shape analysis of automatically segmented femur bones: Data from the osteoarthritis initiative (2016) *Proceedings - International Symposium on Biomedical Imaging*, 2016-June, art. no. 7493351, pp. 651-655.
- [134] A. Aprovitola, L. Gallo. Knee bone segmentation from MRI: A classification and literature review (2016) *Biocybernetics and Biomedical Engineering*, 36 (2), pp. 437-449.
- [135] M. Khanmohammadi, R.A. Zoroofi, T. Nishii, H. Tanaka, Y. Sato. A hybrid technique for thickness-map visualization of the HIP cartilages in MRI (2009) *IEICE Transactions on Information and Systems*, E92-D (11), pp. 2253-2263.
- [136] J. Pang, P. Y. Li, M. Qiu, W. Chen, L. Qiao. Automatic Articular Cartilage Segmentation Based on Pattern Recognition from Knee MRI Images (2015) *Journal of Digital Imaging*, 28 (6), pp. 695-703.
- [137] K. Zhang, W. Lu, P. Marziliano. Automatic knee cartilage segmentation from multi-contrast MR images using support vector machine classification with spatial dependencies (2013) *Magnetic Resonance Imaging*, 31 (10), pp. 1731-1743.
- [138] S. Aja-Fernández, A.H. Curiale, G. Vegas-Sánchez-Ferrero. A local fuzzy thresholding methodology for multiregion image segmentation (2015) *Knowledge-Based Systems*, 83 (1), pp. 1-12.
- [139] S. M. E. Harb, N. A. M. Isa, S. Salamah. New adaptive interpolation scheme for image upscaling (2016) *Multimedia Tools and Applications*, 75 (12), pp. 7293-7325.
- [140] J. B. MacQueen. (1967). Some Methods for classification and Analysis of Multivariate Observations. *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability. I. University of California Press.* pp. 281-297. MR 0214227. Zbl 0214.46201. Retrieved 2009-04-07.

- [141] M. Mahajan, P. Nimbhorkar, K. Varadarajan. (2009). "The Planar k-Means Problem is NP-Hard". *Lecture Notes in Computer Science*. 5431: 274–285. doi:10.1007/978-3-642-00202-1_24.
- [142] T. Kanungo, D. M. Mount, N. S. Netanyahu, C. D. Piatko, R. Silverman, A. Y. Wu. (2002). "An efficient k-means clustering algorithm: Analysis and implementation" *IEEE Trans. Pattern Analysis and Machine Intelligence*. 24: 881–892. doi:10.1109/TPAMI.2002.1017616. Retrieved 2009-04-24.
- [143] J. Kubicek, J. Valosek, M. Penhaker, I. Bryjova. Extraction of chondromalacia knee cartilage using multi slice thresholding method (2016) *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, 165, pp. 395-403.
- [144] J. Kubicek, I. Bryjova, M. Penhaker, M. Kodaj, M. Augustynek. Extraction of myocardial fibrosis using iterative active shape method (2016) *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9621, pp. 698-707.
- [145] I. Bryjova, J. Kubicek, M. Dembowski, M. Kodaj, M. Penhaker. Reconstruction of 4D CTA brain perfusion images using transformation methods, (2016) *Advances in Intelligent Systems and Computing*, 423, pp. 203-211.
- [146] J. Kubicek, J. Valosek, M. Penhaker, I. Bryjova, J. Grepl. Extraction of blood vessels using multilevel thresholding with color coding (2016) *Lecture Notes in Electrical Engineering*, 362, pp. 397-406.
- [147] J. Kubicek, M. Penhaker, K. Pavelova, A. Selamat, R. Hudak, J. Majernik. Segmentation of MRI data to extract the blood vessels based on fuzzy thresholding (2015), *Studies in Computational Intelligence*, 598, pp. 43-52.
- [148] J. Kubicek, M. Penhaker. Fuzzy algorithm for segmentation of images in extraction of objects from MRI (2014), Proceedings of the 2014 *International Conference on Advances in Computing, Communications and Informatics*, ICACCI 2014, art. no. 6968264, pp. 1422-1427.
- [149] J. Kubicek, M. Penhaker, I. Bryjova, M. Kodaj. Articular cartilage defect detection based on image segmentation with colour mapping (2014), *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8733, pp. 214-222.
- [150] B. Bouchon-Meunier. Aggregation and Fusion of Imperfect Information, *Physica-Verlag*, Heidelberg, Germany, 1997.
- [151] M. Detyniecki. Mathematical aggregation operators and their application to video querying, Doctoral thesis - research report 2001-002, *Laboratoire d'Informatique de Paris 6*, 2000.

- [152] J. Dombi. Basic concepts for the theory of evaluation: The aggregative operator, *European Journal of Operational Research* 10, 282-293, 1982.
- [153] D. Yu. A scientometrics review on aggregation operator research (2015) *Scientometrics*, 105 (1), pp. 115-133.
- [154] V. Torra. Aggregation operators for evaluating alternatives (2010) *Studies in Fuzziness and Soft Computing*, 254, pp. 65-76.
- [155] Bose, A., Mali, K. Fuzzy-based artificial bee colony optimization for gray image segmentation (2016) *Signal, Image and Video Processing*, 10 (6), pp. 1089-1096.
- [156] Khairuzzaman, A.K.M., Chaudhury, S. Multilevel thresholding using grey wolf optimizer for image segmentation (2017) *Expert Systems with Applications*, 86, pp. 64-76.

Publikační činnost autora

Publikace na téma disertační práce

- [A.1] Kubicek, J., Timkovic, J., Slonka, J., Penhaker, M., Augustynek, M. & Bryjova, I. 2016, "Optical nerve segmentation using the active shape method", Lekar a Technika, vol. 46, no. 1, pp. 13-20.
- [A.2] Kubicek, J., Bryjova, I., Penhaker, M., Augustynek, M. *Extraction of myocardial fibrosis from MR using fuzzy soft thresholding algorithm* (2016) Proceedings - 2016 5th IIAI International Congress on Advanced Applied Informatics, IIAI-AAI 2016, art. no. 7557566, pp. 1-6.
- [A.3] Kubicek, J., Penhaker, M., Bryjova, I., Augustynek, M. *Classification method for macular lesions using fuzzy thresholding method* (2016) IFMBE Proceedings, 57, pp. 239-244.
- [A.4] Kubicek, J., Bryjova, I., Penhaker, M., Kodaj, M., Augustynek, M. *Surface of articular cartilage extraction using fuzzy C-means segmentation* (2016) Studies in Computational Intelligence, 642, pp. 209-219.
- [A.5] Kubicek, J., Bryjova, I., Penhaker, M. *Macular lesions extraction using active appearance method* (2016) Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST, 165, pp. 438-447.
- [A.6] Kubicek, J., Valosek, J., Penhaker, M., Bryjova, I. *Extraction of chondromalacia knee cartilage using multi slice thresholding method* (2016) Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST, 165, pp. 395-403.
- [A.7] Kubicek, J., Bryjova, I., Penhaker, M., Kodaj, M., Augustynek, M. *Extraction of myocardial fibrosis using iterative active shape method* (2016) Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 9621, pp. 698-707.
- [A.8] Kubicek, J., Bryjova, I., Penhaker, M., Javurkova, J., Kolarcik, L. *Segmentation of macular lesions using active shape contour method*, (2016) Advances in Intelligent Systems and Computing, 423, pp. 213-221.
- [A.9] Bryjova, I., Kubicek, J., Dembowski, M., Kodaj, M., Penhaker, M. *Reconstruction of 4D CTA brain perfusion images using transformation methods*, (2016) Advances in Intelligent Systems and Computing, 423, pp. 203-211.
- [A.10] Kubicek, J., Valosek, J., Penhaker, M., Bryjova, I., Grepl, J. *Extraction of blood vessels using multilevel thresholding with color coding* (2016) Lecture Notes in Electrical Engineering, 362, pp. 397-406.
- [A.11] Kubicek, J., Timkovic, J., Augustynek, M., Penhaker, M., Pokrývková, M. *Optical nerve disc segmentation using circular integro differential operator* (2016) Lecture Notes in Electrical Engineering, 362, pp. 387-396.

- [A.12] Kubicek J., Penhaker M., Pavelova K., Selamat A., Hudak R., Majernik J. *Segmentation of MRI data to extract the blood vessels based on fuzzy thresholding* (2015), *Studies in Computational Intelligence*, 598, pp. 43-52.
- [A.13] Kubicek, J., Penhaker, M., *Fuzzy algorithm for segmentation of images in extraction of objects from MRI* (2014), *Proceedings of the 2014 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2014*, art. no. 6968264, pp. 1422-1427.
- [A.14] Kubicek, J., Penhaker, M., Bryjova, I., Kodaj, M., *Articular cartilage defect detection based on image segmentation with colour mapping* (2014), *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8733, pp. 214-222.
- [A.15] Kubicek, J., Timkovic, J., Penhaker, M., Augustynek, M., Bryjova, I., Kasik, V. *Extraction of optical disc geometrical parameters with using of active snake model with gradient directional information* (2017) *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10192 LNAI, pp. 445-454.
- [A.16] Kubicek, J., Bryjova, I., Valosek, J., Penhaker, M., Augustynek, M., Cerny, M., Kasik, V. *Segmentation of vascular calcifications and statistical analysis of calcium score* (2017) *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10192 LNAI, pp. 455-464.
- [A.17] Kubicek, J., Augustynek, M., Penhaker, M., Bryjova, I., Peter, L. *Multiregional fuzzy thresholding segmentation completed by spatial median aggregation: Modeling and segmentation of early pathological findings of articular cartilage* (2018) *IFMBE Proceedings*, 65, pp. 876-879.
- [A.18] Kubicek, J., Vicianova, V., Penhaker, M., Augustynek, M. *Time deformable segmentation model based on the active contour driven by Gaussian energy distribution: Extraction and modeling of early articular cartilage pathological interruptions* (2017) *Frontiers in Artificial Intelligence and Applications*, 297, pp. 242-255.
- [A.19] Kubicek, J., Kosturikova, J., Penhaker, M., Augustynek, M., Kuca, K. *Segmentation based on gabor transformation with machine learning: Modeling of retinal blood vessels system from retcam images and tortuosity extraction* (2017) *Frontiers in Artificial Intelligence and Applications*, 297, pp. 270-283.
- [A.20] Kubicek, J., Penhaker, M., Ondraczka, T., Machacek, Z., Cerny, M., Augustynek, M., Maresova, P. *Automated extraction and modeling of calcifications and blood stream volumetric parameters* (2017) *Frontiers in Artificial Intelligence and Applications*, 297, pp. 256-269.

- [A.21] Bryjova, I., Kubicek, J., Molnarova, K., Peter, L., Penhaker, M., Kuca, K. *Multiregional Segmentation Modeling in Medical Ultrasonography: Extraction, Modeling and Quantification of Skin Layers and Hypertrophic Scars* (2017) Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 10449 LNAI, pp. 182-192.

Ostatní publikace

- [B.1] Bryjova, I., Kubicek, J., Moravec, J., Stetinsky, J., Penhaker, M. *The evaluation of light conditions influence and corrections upon Doppler blood perfusion imagining* (2016) Advances in Electrical and Electronic Engineering, 14 (4Special Issue), pp. 421-428.
- [B.2] Bryjova, I., Kubicek, J. *The software application for the contrast agent optimization within radiodiagnostic examination* (2016) Proceedings - 2016 5th IIAI International Congress on Advanced Applied Informatics, IIAI-AAI 2016, art. no. 7557567, pp. 7-12.
- [B.3] Penhaker, M., Geyerova, R., Kubicek, J., Augustynek, M., Panackova, K., Novak, V. *Weariness and vigilance data mining using mobile platform assessment* (2016) Proceedings - 2016 5th IIAI International Congress on Advanced Applied Informatics, IIAI-AAI 2016, art. no. 7557568, pp. 13-18.
- [B.4] Bryjová, I., Kubicek, J., Skutova, H. *Comparison and classification of acoustic levels of MRI sequences* (2016) IFMBE Proceedings, 57, pp. 768-772.
- [B.5] Oczka, D., Penhaker, M., Knybel, L., Kubicek, J., Selamat, A. *Design and implementation of an algorithm for system of exposure limit in radiology* (2016) Studies in Computational Intelligence, 642, pp. 433-443.
- [B.6] Peter, L., Vorek, I., Massot, B., Kubicek, J. *Determining the state of cardiovascular system using non-invasive multichannel photoplethysmography* (2016) Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST, 165, pp. 404-412.
- [B.7] Peter, L., Vorek, I., Massot, B., Kubicek, J. *Multichannel photoplethysmography: Developing of precise measuring device for analysis of cardiovascular systém* (2016) Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST, 165, pp. 413-419.
- [B.8] Augustynek, M., Sterba, J., Cihak, J., Kubicek, J., Penhaker, M. *Diagnosis of vascular access for hemodialysis using software application* (2016) Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST, 165, pp. 420-427.
- [B.9] Kubicek, J., Rehacek, T., Penhaker, M., Bryjova, I. *Software simulation of CT reconstructions and artifacts* (2016) Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST, 165, pp. 428-437

- [B.10] Augustynek, M., Kubicek, J., Cerny, M., Bachrata, M. *Model kidney function in stabilizing of blood pressure* (2016) Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 9621, pp. 430-439.
- [B.11] Augustynek, M., Zemanova, A., Kubicek, J., Penhaker, M. *Model of drugs penetration through biological membrane* (2016) Lecture Notes in Electrical Engineering, 362, pp. 481-492.
- [B.12] Grepl, J., Penhaker, M., Kubicek, J., Liberda, A., Mashinchi, R. *Real time signal detection and computer visualization of the patient respiration* (2016) Lecture Notes in Electrical Engineering, 362, pp. 783-793.
- [B.13] Kubicek, J., Penhaker, M., Grepl, J., Selamat, A., Majernik, J., Hudak, R., Snorik, J., Augustynek, M. *Hemodynamic parameters measurement using pulsed doppler effect* (2015) IFAC Proceedings Volumes (IFAC-PapersOnline), 48 (4), pp. 409-412.
- [B.14] Penhaker, M., Kubicek, J., Grepl, J., Heczko, M., Augustynek, M. *Implementation of controlled pacemaker* (2015) IFAC Proceedings Volumes (IFAC-PapersOnline), 48 (4), pp. 413-417.
- [B.15] Grepl, J., Penhaker, M., Kubicek, J., Liberda, A., Selamat, A., Majernik, J., Hudak, R. *Real time breathing signal measurement: Current methods* (2015) IFAC Proceedings Volumes (IFAC-PapersOnline), 48 (4), pp. 153-158.
- [B.16] Kubicek, J., Penhaker, M., *Measurement and simulation of pacemaker supply management* (2014), Studies in Computational Intelligence, 551, pp. 265-273.
- [B.17] Kubicek, J., Penhaker, M., Kahankova, R., *Design of a synthetic ECG signal based on the Fourier series* (2014), Proceedings of the 2014 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2014, art. no. 6968312, pp. 1881-1885.
- [B.18] Kubicek, J., *Creation of the beam hardening artifact* (2014), IFMBE Proceedings, 43, pp. 196-198.
- [B.19] Grepl, J., Penhaker, M., Kubicek, J., Prokop, J., Peter, L., *Pressure distribution measurement of close fitting clothes on human body* (2014), IFMBE Proceedings, 43, pp. 436-439.
- [B.20] Kubicek, J., Penhaker, M., *Guidelines for modelling BED in simultaneous radiotherapy* (2014), IFMBE Proceedings, 43, pp. 271-274.
- [B.21] Kubicek, J., Penhaker, M., Felzl, D., Cvek, J., *Guidelines for modelling BED in simultaneous radiotherapy of two volumes: Tpv1 and tpv2* (2013), SAMI 2013 - IEEE 11th International Symposium on Applied Machine Intelligence and Informatics, Proceedings, art. no. 6480960, pp. 131-135.

- [B.22] Bryjová, I., Kubíček, J., Kašík, V., Peter, L., Kamenský, D., Klosová, H. *Design of the DSCI Skin Colorimeter: Pilot Testing on Hypertrophic Burn Scars* (2016) IFAC-PapersOnLine, 49 (25), pp. 499-504.
- [B.23] Ondraczka, T., Machacek, Z., Kubicek, J., Bryjova, I., Cerny, M., Koziorek, J., Prochazka, V. *Automated image detection of the main bloodstream stem from CT angiography image* (2016) IFAC-PapersOnLine, 49 (25), pp. 109-114.
- [B.24] Kubicek, J., Bryjova, I., Klosova, H., Stetinsky, J., Penhaker, M. *The modelling of the post-operative perfusion in burns from LDI data* (2017) Advances in Electrical and Electronic Engineering, 15 (1), pp. 63-70.
- [B.25] Svobodova, B., Penhaker, M., Kasik, V., Augustynek, M., Kubicek, J. (2017) SAMI 2017 - IEEE 15th International Symposium on Applied Machine Intelligence and Informatics, Proceedings, art. no. 7880345, pp. 417-422.
- [B.26] Penhaker, M., Novakova, M., Knybel, J., Kubicek, J., Grepl, J., Kasik, V., Zapletal, T. *Breathing Movement Analysis for Adjustment of Radiotherapy Planning* (2017) Studies in Computational Intelligence, 710, pp. 105-116.
- [B.27] Kubicek, J., Penhaker, M., Bryjova, I., Augustynek, M., Zapletal, T., Kasik, V. *Tracking of Bone Reparation Process with Using of Periosteal Callus Extraction Based o Fuzzy C-means Algorithm* (2017) Studies in Computational Intelligence, 710, pp. 271-280.
- [B.28] Kubicek, J., Augustynek, M., Penhaker, M., Cerny, M., Bryjova, I. *Analysis and dynamical simulation of heart rate influence upon physical load* (2017) Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 10486 LNCS, pp. 325-333.
- [B.29] Kubicek, J., Bryjova, I., Faltynova, K., Penhaker, M., Augustynek, M., Maresova, P. *Evaluation of Gama Analysis Results Significance Within Verification of Radiation IMRT Plans in Radiotherapy* (2017) Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 10449 LNAI, pp. 541-548.

Publikace vzdělávací

KUBÍČEK, J. *Zpracování medicínských obrazových dat*. Opava: SLEZSKÁ UNIVERZITA v Opavě, Filozoficko-přírodovědecká fakulta, Ústav fyziky, 2014, 141 s. ISBN 978-80-7248-941-1.

PENHAKER, M.; KUBÍČEK, J.; SLEZSKÁ UNIVERZITA. Ústav fyziky. *Matematické modelování dat pro vědecké účely*. 1. vyd. Opava: Slezská univerzita v Opavě, Filozoficko-přírodovědecká fakulta, Ústav fyziky, 2014. 327 s. p. ISBN 978-80-7248-942-8.

PENHAKER, M.; KUBÍČEK, J.; SLEZSKÁ UNIVERZITA. Ústav fyziky. *Snímače a senzory v biomedicině*. 1. vyd. Opava: Slezská univerzita v Opavě, Filozoficko-přírodovědecká fakulta, Ústav fyziky, 2014. 129 s. p. ISBN 978-80-7248-943-5.

Člen konferenční komise

ACIIDS 2018 (organizátor speciální sekce: ISaMiB 2018 - Special Session on Intelligent Systems and Methods in Biomedicine)

ICITS 2018

ALLSENSORS 2018

SoMeT 2017

yberc 2016

Školitel

bakalářské práce: 13 obhájených

Oponent/konzultant

2 bakalářské práce a 7 magisterských prací

Pedagogická činnost

Lékařské zobrazovací systémy I (2013 - 2016)

MATLAB a simulace (2012 - 2016)

Biokybernetika (2014 - 2016)

Aplikovaná umělá inteligence (2017/2018)

Projekty – hlavní řešitel

TACR GAMA, PP1: Pre SEED, (Technology Agency of Czech Republic), Project TG01010137, Sub-project: Segmentation of image data of articular cartilage and vascular system to extract pathological findings, CZ: Segmentace obrazových dat artikulární chrupavky a cévního systému s cílem extrakce patologických nálezů, VSB-Technical university of Ostrava, Member of working group. 2015-2016 (684 767 CZK, 26 337 €)

Projekty – člen řešitelského týmu

Biomedical engineers systems XI, Intern grants system, SP2015/179, 2015 Faculty of Electrical Engineering and Computer Science, VSB - TU Ostrava. Applicant and Leader of working group of VSB - TU Ostrava (1 490 000, CZK, 59 000 €)

Biomedical engineers systems X, Intern grants system, SP2014/194, 2014 Faculty of Electrical Engineering and Computer Science, VSB - TU Ostrava. Applicant and Leader of working group of VSB - TU Ostrava (1 500 000, CZK, 60 000 €)

Biomedical engineers systems IX, Intern grants system, SP42013/35, 2013, Faculty of Electrical Engineering and Computer Science VSB - TU Ostrava. Applicant and Leader of working group of VSB - TU Ostrava (1 490 000, CZK, 59 000 €)

Biomedical engineers systems VIII, Intern grants system, SP2012/114, Faculty of Electrical Engineering and Computer Science, VSB - TU Ostrava. Applicant and Leader of working group of VSB - TU Ostrava (800 000, CZK, 32 000 €)

Biomedical engineers systems VII, Intern grants system, SP2011/21, Faculty of Electrical Engineering and Computer Science, VSB - TU Ostrava. Applicant and Leader of working group of VSB - TU Ostrava (177 000,- CZK, 7 800 €)

Ostatní výsledky

Software

Jan Kubiček, Iveta Bryjová. CaSco 1.0 Testování algoritmu na reálných klinických datech.. Vysoká škola báňská - Technická univerzita Ostrava, 2016

Jan Kubiček, Iveta Bryjová. CartilagIm 1.0.0 Algoritmus obrazové segmentace artikulární chrupavky z MRI. Vysoká škola báňská - Technická univerzita Ostrava, 2015