

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2022

Bc. Petra Dohnalová



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

SEGMENTACE KARDIOLOGICKÝCH MR OBRAZŮ

SEGMENTATION OF CARDIAC MR IMAGES

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Petra Dohnalová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Radovan Jiřík, Ph.D.

BRNO 2022

Diplomová práce

magisterský navazující studijní program **Bioinženýrství**

Ústav biomedicínského inženýrství

Studentka: Bc. Petra Dohnalová

ID: 203179

Ročník: 2

Akademický rok: 2021/22

NÁZEV TÉMATU:

Segmentace kardiologických MR obrazů

POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte metody segmentace myokardu levé komory používané pro MR obrazy. 2) Navrhněte a implementujte algoritmus vybrané segmentační metody. 3) Ilustrujte funkčnost algoritmu na dodaném MRI datasetu. 4) Odladte algoritmus na dodaných datasetech studie fibrózy myokardu. 5) Porovnejte přesnost algoritmu s manuální segmentací. 6) Vyhodnoťte vliv fibrózy myokardu na objem levé komory a ejekční frakci.

DOPORUČENÁ LITERATURA:

[1] LEKADIR, Karim, Jichao ZHAO, Marta NUÑEZ-GARCIA, Chen CHEN, et al. Deep Learning for Cardiac Image Segmentation: A Review. *Frontiers in Cardiovascular Medicine*, 7(25), 2020, doi:10.3389/fcvm.2020.00025
[2] PETITJEAN, Caroline a Jean Nicolas DACHER, A review of segmentation methods in short axis cardiac MR images. *Medical Image Analysis*, 15(2), 169–184, 2011, doi:10.1016/J.MEDIA.2010.12.004

Termín zadání: 7.2.2022

Termín odevzdání: 20.5.2022

Vedoucí práce: Ing. Radovan Jiřík, Ph.D.

Konzultant: Ing. Jiří Vitouš

doc. Ing. Radim Kolář, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

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

ABSTRAKT

Tato diplomová práce se zabývá vlivem fibrózy myokardu na srdeční činnost, změny v end-diastolickém a end-systolickém objemu, zároveň i změnami v ejekční frakci. Teoretická část je zaměřena na prostudování metod používaných při segmentaci levé komory srdeční. Cílem je poté implementovat algoritmus vhodný na segmentaci levé komory na dodaném datasetu. Na základě segmentace se sleduje vliv myokardiální fibrózy na skupině potkanů s indukovanou fibrózou, zároveň jsou data porovnávána s kontrolní skupinou zdravých potkanů.

KLÍČOVÁ SLOVA

segmentace, levá komora srdeční, fibróza myokardu, ejekční frakce, potkan

ABSTRACT

This diploma thesis focuses on the influence of myocardial fibrosis on cardiac activity, changes in end-diastolic and end-systolic volume, as well as changes in ejection fraction. The theoretical part is focused on studying the methods used in left ventricular segmentation. The goal is then to implement an algorithm suitable for left ventricular segmentation on the supplied dataset. Based on segmentation, the effect of myocardial fibrosis on the group of rats with induced fibrosis is monitored, at the same time the data are compared with the control group of healthy rats.

KEYWORDS

segmentation, left ventricle, myocardial fibrosis, ejection fraction, rat

DOHNALOVÁ, Petra. *Segmentace Kardiologických MR obrazů*. Brno, 2022, 67 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Radovan Jiřík, PhD.

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Segmentace Kardiologických MR obrazů“ jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

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

Brno

.....

podpis autorky

PODĚKOVÁNÍ

Ráda bych poděkoval vedoucímu diplomové práce panu Ing. Radovanu Jiříkovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci. Dále bych ráda poděkovala Ing. Jiřímu Vítoušovi, za metodickou a odbornou pomoc a další cenné rady.

Obsah

1 Úvod	11
2 Teoretická část	12
2.1 Srdce	12
2.1.1 Ejekční frakce	13
2.1.2 Získání dat pro výpočet EF	13
2.1.3 Krátká osa srdeční	14
2.2 Metody předzpracování snímků	15
2.2.1 Transformace dat	15
2.2.2 Prahování	16
2.2.3 Ekvalizace histogramu	16
2.2.4 Gaussovský filtr	17
2.2.5 Homomorfická filtrace	17
2.2.6 Gamma transformace	18
2.2.7 Morfologické operace	18
2.2.8 Prokládání kvadratickým polynomiálem	19
2.3 Segmentační metody	19
2.3.1 Metody segmentace založené na obrazových vlastnostech	19
2.3.2 Metody segmentace založené na pixelových vlastnostech	20
2.3.3 Metody segmentace založené na deformačních modelech	21
2.3.4 Metody segmentace active shape a appearance models	24
2.3.5 Metody segmentace založené na atlasových znalostech a registraci obrazů	24
2.4 Hodnocení úspěšnosti segmentace	25
2.4.1 Jaccardův index	25
2.4.2 Dice koeficient	25
2.4.3 Výpočet odchylky měření	26
3 Praktická část	27
3.1 Programové řešení	27
3.1.1 Předzpracování dat	28
3.1.2 Implementovaný algoritmus	36
3.1.3 Ukládání masek	39
3.1.4 Ukázkové skripty segmentačního algoritmu	40
3.2 Vyhodnocení přesnosti algoritmu	42
3.2.1 Dice koeficient	42
3.2.2 Možné zdroje chyb	45

3.2.3	Vyhodnocení vypočtených objemů	47
3.2.4	Ukázkové skripty vyhodnocení algoritmu	53
3.3	Vyhodnocení vlivu fibrózy	54
4	Závěr	62
	Literatura	63

Seznam obrázků

2.1	Levá a pravá komora z pohledu krátké osy srdeční, [9]	15
3.1	Ukázka snímku pořízeného během měření zdravé skupiny potkanů, 14. měření, 4. řez	28
3.2	Vývojový diagram implementovaného algoritmu	29
3.3	Upravený snímek po normalizaci, Gaussovské filtraci a vynulování, 14. měření, 5. řez, s manuálně upraveným kontrastem	31
3.4	Vypočítaný kvadratický polynomiál použitý na proložení snímku ze 14. měření, 4. řez	32
3.5	Snímek po vyrovnání jasů pomocí proložení kvadratickým polynomi- álem, 14. měření, 4. řez, s manuálně upraveným kontrastem	33
3.6	Histogram snímku před ekvalizací histogramu, 14. měření, 4. řez . . .	34
3.7	Histogram snímku po ekvalizaci histogramu, 14. měření, 4. řez	34
3.8	Snímek po ekvalizaci histogramu, 14. měření, 4. řez	35
3.9	Předzpracovaný snímek použitý pro následnou segmentaci, 14. mě- ření, 4. řez	36
3.10	Hranová mapa snímku, 14. měření, 4. řez	37
3.11	Výsledek segmentace levé komory během diastoly, 14. měření, 4. řez, s manuálně upraveným kontrastem	39
3.12	Výsledná vytvořená maska vysegmentované levé komory, bíle ozna- čena oblast levé komory, černě oblast mimo komoru, 14. měření, 4. řez	40
3.13	Boxplot znázorňující rozložení hodnot dice koeficientů v rámci jed- notlivých řezů, během segmentace diastol	44
3.14	Boxplot znázorňující rozložení hodnot dice koeficientů v rámci jed- notlivých řezů, během segmentace systol	45
3.15	Ukázka snímku diastoly (vlevo) a systoly (vpravo), ze 14. měření, 3. řez, s manuálně upraveným kontrastem	46
3.16	Ukázka snímku s nezřetelnou levou komorou, získaného ve třetím řezu 12. měření v okamžiku systoly, s manuálně upraveným kontrastem . .	47
3.17	Ukázka špatně předzpracovaného snímku levé komory, získaného ve třetím řezu 10. měření v okamžiku diastoly	48
3.18	Boxploty znázorňující porovnání vypočtených objemů diastoly (vlevo) a systoly (vpravo) v závislosti na použité manuální / auto- matické segmentaci	49
3.19	Boxplot znázorňující porovnání vypočtených hodnot ejekční frakce v závislosti na použité manuální / automatické segmentaci	49

3.20	Ukázka masek vytvořených pro snímky diastol, automatická segmentace (horní řádek) a manuální segmentace (spodní řádek). První sloupec: 5. měření, 3. řez, druhý sloupec: 14. měření, 4. sloupec, třetí sloupec: 24. měření, 3. řez	51
3.21	Ukázka masek vytvořených pro snímky systol, automatická segmentace (horní řádek) a manuální segmentace (spodní řádek). První sloupec: 3. měření, 6. řez, druhý sloupec: 16. měření, 5. sloupec, třetí sloupec: 23. měření, 5. řez	52
3.22	Boxploty znázorňující získané end-diastolické objemy u kontrolní skupiny potkanů , v průběhu tří postupných měření, automatická segmentace (vlevo), manuální segmentace (vpravo)	56
3.23	Boxploty znázorňující získané end-diastolické objemy u fibrotické skupiny potkanů , v průběhu tří postupných měření, automatická segmentace (vlevo), manuální segmentace (vpravo)	56
3.24	Boxploty znázorňující získané end-systolické objemy u kontrolní skupiny potkanů , v průběhu tří postupných měření, automatická segmentace (vlevo), manuální segmentace (vpravo)	57
3.25	Boxploty znázorňující získané end-systolické objemy u fibrotické skupiny potkanů , v průběhu tří postupných měření, automatická segmentace (vlevo), manuální segmentace (vpravo)	57
3.26	Ukázka zbytnění myokardu vlivem indukované fibrózy u sledované fibrotické skupiny (spodní řádek) oproti kontrolní skupině (horní řádek) během třetího měření. Ukázka během diastoly (levý sloupec) a systoly (pravý sloupec), s manuálně upraveným kontrastem	58
3.27	Boxploty znázorňující vypočtené hodnoty ejekčních frakcí v průběhu měření, pro kontrolní skupinu , automatická segmentace (vlevo), manuální segmentace (vpravo)	59
3.28	Boxploty znázorňující vypočtené hodnoty ejekčních frakcí v průběhu měření, pro fibrotickou skupinu , automatická segmentace (vlevo), manuální segmentace (vpravo)	59

Seznam tabulek

3.1	Vypočtené hodnoty dice koeficientů v případě segmentace diastol, pro jednotlivé řezy zvlášť v řádcích, i pro všechny získané dice koeficienty, zaokrouhleno na dvě desetinná místa	43
3.2	Vypočtené hodnoty dice koeficientů v případě segmentace diastol, pro jednotlivé řezy zvlášť v řádcích, i pro všechny získané dice koeficienty, zaokrouhleno na dvě desetinná místa	44
3.3	Tabulka absolutních chyb pro jednotlivé vypočtené hodnoty EDV, ESV, EF	48
3.4	Tabulka relativních chyb pro jednotlivé vypočtené hodnoty EDV, ESV, EF	50

1 Úvod

V dnešní době se řadí nemoci kardiovaskulárního systému mezi nejrozšířenější onemocnění, zároveň každoročně obsazují první příčky v příčinách úmrtí. I toto je jeden z důvodů, proč je snaha onemocnění cévní soustavy a srdce rozpoznat co nejdříve a tím pádem i zahájit možnou léčbu. Existuje velké množství včasných ukazatelů, které mohou onemocnění kardiovaskulární soustavy predikovat, z tohoto důvodu je vhodné tyto ukazatele sledovat. Mezi takové ukazatele může patřit například ejekční frakce, která ukazuje, jaký je poměr mezi vypuzenou krví do cévního oběhu a celkovým objemem krve v srdci před systolickým stahem. Pomocí tohoto poměru pak lze sledovat průběh nemocí a jejich vliv na fungování srdce, mezi taková možná onemocnění může patřit například myokardiální fibróza.

Pro zjištění hodnoty ejekční frakce je nezbytné znát end-systolický objem, objem krve, nacházející se v srdeční komoře po skončení systolického stahu a objem end-diastolický, tedy objem krve v komoře po naplnění během diastoly. Zjištění těchto objemů se provádí často neinvazivními zobrazovacími metodami, v průběhu srdečního cyklu jsou násnímány snímky srdce, ve snímcích jsou následně označeny zájmové oblasti, ze kterých se poté dopočítávají například právě hodnoty ejekční frakce.

Cílem teoretické části je tak prostudovat možné segmentační přístupy nabízející se pro automatické či poloautomatické označování levé komory srdeční. Na toto bude navazovat praktická část, kde je vybraný algoritmus implementován a ozkoušen na dodaném reálném měření vzniklém během studia myokardiální fibrózy na ÚPT, zároveň je taktéž vyhodnocena úspěšnost segmentačního algoritmu porovnáním s provedenou manuální segmentací.

Poslední část se věnuje porovnání vypočtených end-systolických, end-diastolických objemů a z toho vzešlých hodnot ejekčních frakcí, jejich změny a důvody změn v průběhu měření. Toto je diskutováno zároveň s vlivem myokardiální fibrózy právě na ejekční frakci.

2 Teoretická část

2.1 Srdce

Neinvazivní zobrazovací metody hrají v dnešní době neodmyslitelnou roli v diagnózách a následných léčbách kardiovaskulárních nemocí. Mezi zobrazovací systémy, které jsou často používané jak pro diagnostické účely, tak pro fyziologické porozumění lze zařadit počítačovou tomografii (CT), pozitronovou emisní tomografii (PET), ultrazvuk (US), jednofotonovou emisní výpočetní tomografii (SPECT) či magneticou rezonanci (MR). S pomocí těchto modalit lze lépe rozpoznat různé nemoci a prohloubit znalosti mezi zdravou a postiženou tkání. Do oblasti onemocnění kardiovaskulárního systému se řadí primárně onemocnění srdce a cévní soustavy. Konkrétněji lze jmenovat ischemické choroby - srdeční, dolních končetin, cévní mozková příhoda, ale také vysoký krevní tlak. Společně s rakovinovým onemocněním, chronickým respiračním nemocem a diabetem se řadí kardiovaskulární onemocnění mezi nejčastější příčiny úmrtí. [1]

Mezi faktory vzniku a následného postupného selhávání srdce se řadí fibróza myokardu. Obecně může nastat fibróza u různých orgánů nacházejících se v lidském těle, při fibrotickém onemocnění dochází ke zmnožení vazivové tkáně určitého orgánu, zbytnění vazivové tkáně je často na úkor zdravé tkáně, která pak není schopna vykonávat svou činnost v původním rozsahu. V případě fibrózy myokardu se jedná o nadbytečné ukládání extracelulární matrix v srdeční svalovině. Z tohoto důvodu je pak srdeční svalovina méně poddajná, tužší, srdce musí vykonávat více práce pro zajištění stejných funkcí, při stejné fyziologické zátěži a to může přispívat k postupnému srdečnímu selhávání. [2]

Mezi indikátory ukazující na možné kardiovaskulární onemocnění se řadí velikost, mohutnost, struktura levé komory srdeční a parametry odvozené z těchto hodnot. Samotná diagnóza spočívá většinou v prvním kroku na získání obrazových informací z různých zobrazovacích modalit, ze kterých lze získat hodnotné informace jak o anatomii, tak o samotné funkčnosti srdce a cév. V druhém kroku lze potom takto získaná data zpracovat, kvantifikovat a interpretovat. Do skupiny indikátorů správného fungování srdce a jeho morfologických parametrů tak lze zařadit end-systolický objem (ESV), end-diastolický objem (EDV), ejekční frakci (EF), objem a tloušťku stěn komor. [3]

2.1.1 Ejekční frakce

Ejekční frakce je jedním z ukazatelů systolické funkce levé komory. Jedná se o podíl mezi systolickým objemem a end-diastolickým objemem levé komory, udává množství krve, které je vypuzeno do krevního oběhu během jednoho stahu.

$$EF = \frac{SV}{EDV} \cdot 100 [\%], \quad (2.1)$$

kde EF je ejekční frakce, SV je systolický objem a EDV je end-diastolický objem levé komory. End-diastolický objem je naopak objem krve, který se nachází v levé komoře srdeční po diastole, v okamžiku před systolou. End-systolický objem je objem krve, který zůstane v levé komoře po systole. Jedná se tedy o krev, která nebyla během stahu vypuzena do cévního řečiště. Systolický objem je objem krve vypuzený z levé komory během jednoho srdečního stahu, lze ho získat z rozdílu end-diastolického a end-systolického objemu.

$$SV = EDV - ESV, \quad (2.2)$$

kde SV je systolický objem, EDV je end-diastolický objem a ESV reprezentuje end-systolický objem. [4]

U fyziologicky zdravých jedinců by se měl end-diastolický objem pohybovat okolo hodnoty $EDV = 150$ ml, end-systolický objem by měl být v blízkosti hodnoty $ESV = 50$ ml a systolický objem $SV = 100$ ml. Hodnota ejekční frakce by se tudíž měla u zdravého jedince pohybovat blízko $EF = 67$ %. [5] V případě potkanů se bude jednat o hodnoty vyšší, u fyziologicky zdravých jedinců se bude hodnota pohybovat přibližně kolem $EF = 75 - 80$ %. [6] Změna v hodnotě ejekční frakce může indikovat potíže. Mezi časté případy patří, kdy hodnota ejekční frakce v čase postupně klesá. Tento stav je zapříčiněn snižujícím se systolickým objemem, podíl vypuzené krve je nižší při stejně vykonané práci, vlivem toho se do popředí může dostávat srdeční selhání. [5] Zároveň se ale při sledování ejekční frakce může stát, že se nebude měnit, popřípadě bude růst. K tomuto může docházet primárně ze začátku fibrózy myokardu, kdy srdeční svalovina není schopna se tolik roztáhnout během plnicí fáze, zároveň ale je stále schopná vypudit stejné množství krve. Ve výsledku tak dojde k poklesu end-systolického objemu, což povede na výsledné hodnoty ejekční frakce srovnatelné, či dokonce vyšší, než u zdravých jedinců. [7]

2.1.2 Získání dat pro výpočet EF

Hodnota ejekční frakce může být získána více způsoby, jak neinvazivními metodami, tak invazivními. Invazivní metoda spočívá ve ventrikulografii (zobrazení sr-


dečních dutin) během katetrizace. Mezi neinvazivní metody se řadí echokardiografie, zobrazováním pomocí magnetické resonance, počítačové tomografie, jednofotonové emisní tomografie, pozitronové emisní tomografie a následným dopočtem ze získaných dat. [4]

Při snímání dat pomocí magnetické resonance jsou data sejmuty v různých fázích systoly a diastoly. Pro snažší nalezení přesných okamžiků odpovídajících end-systole a end-diastole v nasnímaných datech probíhá často měření zároveň se záznamem EKG. Na základě nasnímané elektrické aktivity tak lze následně přesněji určit snímky vhodné pro výpočet ejekční frakce. Ve snímcích takto určených jsou následně vysegmentovány hranice endokardu, díky tomu je získána oblast reprezentující dutinu levé komory pro každý řez. Segmentace může proběhnout pomocí manuální segmentace, poloautomatické segmentace či plně automatické segmentace. Tyto získané oblasti jsou následně vynásobeny objemem voxelu (šířka jednotlivých řezů plus mezera mezi jednotlivými řezy), ve výsledku je tak získán objem komory pro určitý řez. Postupně jsou tímto způsobem získány z jednotlivých řezů komorou částečné objemy, které jsou pro získání celkového objemu levé komory sečteny dohromady. Tímto způsobem jsou dopočítány objemy jak pro end-systolu, tak i pro end-diastolu a na základě vypočtených hodnot lze dopočítat i hodnoty ejekční frakce. [8]

2.1.3 Krátká osa srdeční

Při snímání zobrazovacími modalitami se často využívá zobrazovací rovina kolmá na osu spojující srdeční bázi a apex. Tato rovina se nazývá krátká osa srdeční. Na snímcích snímaných z pohledu krátké osy srdeční jsou tak patrné jednotlivé příčné řezy srdcem, můžeme zde dobře identifikovat pravou a levou komoru, stejně tak jsou i dobře patrné mohutnosti srdečního myokardu. Levá komora zde má tvar elipsy až kružnice, pravá komora tvarově připomíná pľlměsí. [9] Ukázka reprezentace levé a pravé komory ve zobrazovací rovině krátké osy srdeční je uvedena na 2.1.

Komory jsou ohraničeny srdeční svalovinou - myokardem, který je u fyziologicky zdravého jedince mohutnější v oblasti levé komory. Toto je způsobeno funkcemi, které mají jednotlivé komory - zatímco pravá komora přečerpává krev do pľic a odolává tím pádem mnohem nižším tlakům, na rozdíl od levé komory, která musí krev vehnat do celého tělního oběhu. [10] Vzhledem k tomu, že pravá komora čelí mnohem nižším tlakům, než komora levá, je myokard pravé komory mnohem tenčí, než myokard komory levé. V průměrném měřítku se jedná o třikrát až šestkrát tenčí svalovinu. [11] V případě snímání srdeční svaloviny pomocí magnetické resonance se u zobrazování pravé komory dostáváme na limitní hodnoty schopnosti prostorového rozlišení této metody. I to je jeden z důvodů, proč se při kvantifikaci srdeční činnosti se spíše zaměřujeme na činnost levé komory a mohutnost myokardu. [9]



Obr. 2.1: Levá a pravá komora z pohledu krátké osy srdeční, [9]

2.2 Metody předzpracování snímků

Pro správné fungování segmentačních algoritmů je většinou potřeba snímky předzpracovat, upravit jasové hodnoty, zvýraznit hrany, potlačit šum, či normalizovat, standardizovat jasové hodnoty. Pomocí předzpracování tak lze docílit potlačení nežádoucích zkreslení nacházejících se ve snímcích a naopak lze zvýraznit prvky napomáhající následné segmentaci. [12] Mezi metody předzpracování snímků může patřit například prosté prahování, filtrace či ekvalizace histogramu. Do oblasti předzpracování obrazů lze zařadit velké množství metod, zde budou uvedeny primárně postupy, které jsou následně využity v praktické části diplomové práce.

2.2.1 Transformace dat

Transformace dat je často jeden ze základních kroků v následném zpracování obrazů. Metody se využívají pro přeškálování dat, aby se hodnoty nacházely ve stejných měřítkách a bylo tak jednodušší je následně zpracovávat.

Jedním ze základních přístupů je normalizace dat, při které dojde k přepočtu hodnot datasetu do rozmezí hodnot $(0, 1)$. Obecný výpočet je

$$I_{norm}(x, y) = \frac{I(x, y) - \min(I)}{\max(I) - \min(I)}, \quad (2.3)$$

kde $I(x, y)$ je hodnota snímku v daném bodě, I je samotný snímek a $I_{norm}(x, y)$ je normalizovaný snímek. Samotný přepočítání si však neporadí například s odlehlými hodnotami, data jsou pouze přepočítána do pevně stanoveného intervalu.

Dalším častým přístupem je standardizace dat. Přístup je velmi podobný, jako v předchozím případě, data jsou ale přeškálovány tak, že jejich střední hodnota je $\mu = 0$ a směrodatná odchylka $\sigma = 1$. Výpočet pak probíhá jako

$$I_{standartized}(x, y) = \frac{I(x, y) - \text{mean}(I)}{\text{std}(I)}. \quad (2.4)$$

Zde $I_{standartized}(x, y)$ je standardizovaný snímek, $I(x, y)$ je hodnota snímku pro daný bod, $\text{mean}(I)$ je střední hodnota celého snímku a $\text{std}(I)$ je směrodatná odchylka vypočtena z celého obrazu. notlivých prvků. Výsledné hodnoty pak mají navzájem všechny stejnou energii, dataset představuje jednotkový vektor. [13]

2.2.2 Prahování

Prahování se může řadit mezi jednodušší, ale často velmi efektivní metody na rozlišení pixelů reprezentujících objekt na snímku a pixely pozadí. Reprezentujícím příkladem pro takto použité prahování může být například detekce tmavých písmen na světlém pozadí, detekce zlomenin a prasklin na snímcích materiálů, či detekování buněk na snímcích z mikroskopu. V tomto případě je výsledkem většinou černobílý obraz, označující pozice, kde se detekovaný objekt nachází. [14]

Za pomoci prahování lze taktéž vytvořit snímek, který bude obsahovat více stupňů šedi, každý reprezentující jinou oblast. Naprahovaný snímek pak může například sloužit jako maska pro dataset říkající, že daný pixel může patřit do hledané oblasti. Jednotlivé hodnoty oddělující stupně šedi jsou často určeny z histogramu snímku. [15]

2.2.3 Ekvalizace histogramu

Ekvalizace histogramu je jedna z metod pomáhající vylepšení kontrastu snímku. Snímek by měl po procesu ekvalizace mít ideálně stejně vysoké sloupce reprezentující jednotlivé stupně šedi v obrazu, měl by být tedy ideálně plochý. Zároveň by sloupce měly být pravidelně rozloženy na celé škále stupňů šedi. Metoda však není schopná rozlišit, zda zvýrazňuje užitečnou složku, či šumové pixely z pozadí.

V prvním kroku výpočtu je vypočtena pravděpodobnostní funkce (PMF - probability mass function), která nese informaci o jednotlivých počtech prvků. Z ní následně

dopočtená kumulativní distribuční funkce (CDF - cumulative distribution function), její výpočet je postupná suma pravděpodobnostní funkce. Kumulativní distribuční funkce je v následujícím kroku vynásobena maximální hodnotou ve snímku, čímž dojde k namapování nových hodnot na původní místa. [16]

2.2.4 Gaussovský filtr

Gaussovský filtr je 2D vyhlazující konvoluční operátor, s jeho použitím jsme schopni potlačit šum v obrazech, zároveň se jeho vlivem snímek rozmazává. Gaussovská funkce je definována směrodatnou odchylkou, která udává šířku kernelu a tím pádem jsou díky ní definovány i filtrační a vyhlazující vlastnosti. Čím vyšší směrodatná odchylka bude, tím větší oblast snímku se podílí na konvoluci, zvyšuje se tak filtrační účinnost, zároveň ale dochází ke zvýšení rozmazání snímku. Ve 2D isotropní formě má Gaussovský kernel tvar

$$G(x, y) = \frac{1}{2 \cdot \pi \cdot \sigma^2} \cdot e^{-\frac{x^2+y^2}{2 \cdot \sigma^2}}, \quad (2.5)$$

kde $G(x, y)$ jsou hodnoty kernelu v jednotlivých bodech, σ je směrodatná odchylka určující míru roztažení kernelu, x, y jsou poziční souřadnice pro jednotlivé body.

Svým chováním odpovídá Gaussovský filtr filtru typu dolní propust - jeho vlivem dochází k propuštění nižších frekvencí, zatímco vysoké frekvence reprezentující detaily jsou odfiltrovány. Ve své podstatě je velmi podobný průměrujícímu filtru, na rozdíl od něj ale přidává různé váhy pixelům - čím blíže ke středu kernelu daný pixel je, tím vyšší bude mít váhu. Díky tomuto váhování jsou mnohem více zachovávány hrany původního snímku. [17]

2.2.5 Homomorfická filtrace

Jedná se o techniku filtrace schopnou potlačit multiplikativní šum, využití nachází u snímků s nelineárním osvětlením. Nelineární osvit snímku může být zapříčiněn například šikmým osvětlením, či různými vzdálenostmi od detektoru. Intenzita každého pixelu snímku je tak rovna součinu hodnoty pixelu scény s náhodnou hodnotou šumové složky, ve snímku se tedy nachází šum multiplikativní.

$$I(x, y) = L(x, y) \cdot N(x, y), \quad (2.6)$$

kde $I(x, y)$ je obraz, $L(x, y)$ je snímaná scéna a $N(x, y)$ je multiplikativní šumová složka. Pro kompenzaci nelineárního osvětlení je třeba odstranit šumovou složku $N(x, y)$. Filtrovaný snímek je nejprve transformován pomocí logaritmu, lze tak využít jednu z

vlastností logaritmických operací, která součin rozdělí na součet logaritmů jednotlivých členů. Takto transformovaná data jsou následně vyfiltrována filtrem typu horní propust, jelikož nelineární osvit se bude projevovat primárně pomalými změnami v nízkých frekvencích. Vyfiltrovaný snímek je následně transformován zpět aplikací exponenciální funkce (funkce inverzní k logaritmické). Výstupní snímek bude mít mnohem více vyrovnaný jas v ploše, než snímek vstupní. [18]

2.2.6 Gamma transformace

Gamma transformace je nelineární operace, která převádí získané nasnímané hodnoty do nelineární závislosti. Velmi často se využívá při úpravách obrazů, kdy snímek takto upravený odpovídá lépe lidskému vnímání. Obraz je transformován podle rovnice

$$I_{transf}(x, y) = I(x, y)^\gamma, \quad (2.7)$$

kde $I(x, y)$ je původní snímek, I_{transf} je snímek transformovaný gamma korekcí a γ je konstanta řídící průběh transformace. V závislosti na použité gamma konstantě dojde k redistribuci různých oblastí pixelových intenzit. [13]

2.2.7 Morfologické operace

Morfologické operace zahrnují postupy na potlačení šumu, zvýraznění hran či zlepšení obrazu. Mezi základní operace patří eroze a dilatace.

V případě eroze je snímek postupně procházen maskou definující požadovaný tvar okolí. Výstupní pixel je pak tvořen minimální hodnotou pixelů okolí. Tato operace odstraňuje jednotlivé pixely, malé shluky pixelů, velmi tenké linky. Objekty na snímku budou zmenšené a ztenčené.

I u dilatace je snímek postupně procházen maskou definující požadovaný tvar okolí, v tomto případě je ale jako výstupní hodnota zapsána maximální intenzita v maskou definovaném okolí. Díky tomu dochází naopak k výplni objektů, zvýraznění malých ostrůvků pixelů, obecně objekty budou ve finálním snímku zvětšené.

Pokud se tyto dvě operace použijí ve sledu za sebou, mluvíme o morfologických operacích otevření, zavření.

Morfologické otevření je eroze následovaná dilatací. Při tomto postupu dojde nejprve k odstranění malých objektů ve snímku, následnou dilatací je snímek vrácen do původního stavu, ovšem již bez odstraněných objektů.

Morfologické uzavření je postup přesně opačný, tedy dilatace následována erozí. Tento postup se naopak bude hodit pro vyplnění mezer a otvorů ve struktuře, vnější tvar struktury však bude taktéž zachován.

Morfologické operace lze aplikovat jak na snímky binární, tak na snímky šedotónové. [13]

2.2.8 Prokládání kvadratickým polynomiálem

Ve snímcích se může nacházet nehomogenita osvětlení, v případě snímků z magnetické rezonance může být způsobená citlivostním profilem RF cívek. Prokládání kvadratickým polynomiálem je postup, kde je pomocí metody nejmenších čtverců postupně nalezen polynomiál, který kopíruje nehomogenní osvit ve snímku, po vydělení snímku tímto polynomiálem by mělo dojít k linearizaci jasu.

Tento polynomiál může být vypočten pomocí fitování rovnice kvadratického polynomiálu na daný obraz, výpočet vede na minimalizaci součtu kvadrátů odchylek, která může být řešena analyticky pomocí soustavy lineárních rovnic. Jednotlivé koeficienty se zde odvozují ze souřadnic a z jasových hodnot. Pomocí metody nejmenších čtverců se tedy v rovnici

$$A \cdot X = Y \quad (2.8)$$

hledají koeficienty X . V této rovnici jsou A koeficienty soustavy rovnic sestavené ze souřadnic a Y jsou jasové hodnoty. Ze znalosti transformačních koeficientů získaných z 2.8 lze poté dopočítat kvadratický polynomiál jako součin koeficientů se všemi souřadnicemi snímku, podléhajících stejné modifikaci. [19]

2.3 Segmentační metody

Segmentace kardiologických dat je v dnešní době velmi používaná, je užitečná v široké škále aplikací, diagnózách, patologických lokalizacích či například intervenčních metodách. Jednou z klasických možností vyznačení levé komory srdeční může být manuální segmentace, nicméně jedná se o časově dlouhý proces, záleží zde na znalostech a zkušenostech, výsledek se tak může při každé segmentaci lišit. I toto je jeden z důvodů, proč je snaha vytvořit algoritmy schopné alespoň částečně, nebo úplně zastoupit práci člověka při segmentaci. [9] Možné segmentační přístupy popsány níže byly vybírány na základě [9].

2.3.1 Metody segmentace založené na obrazových vlastnostech

Segmentační postupy založené na obrazových vlastnostech obsahují různé metody. Jednotlivé přístupy vychází často z morfologických operací, využívá se fuzzy logiky či dynamického programování. [9]

Při postupu založeném na morfologických operacích je na prvním snímku z data-setu reprezentujícího jeden srdeční cyklus nejprve manuálně označen referenční bod značící oblast levé komory. Samotný snímek je následně pomocí gamma korekce transformován tak, aby byla lépe rozlišitelná srdeční svalovina a jednotlivé komory. Obraz je transformován podle rovnice

$$I_{new} = k \cdot I^{gamma}, \quad (2.9)$$

kde k je konstanta násobící obraz, I je původní obraz, $gamma$ je konstanta řídící transformaci a I_{new} je nově vytvořený obraz. Originální obraz je tak nelineárně transformován. Samotná transformace je závislá na zvolených parametrech k a $gamma$. Snímek korigovaný tímto způsobem je následně prahován tak, aby obsahoval pouze několik stupňů šedi a z pozice referenčního bodu umístěného dovnitř levé komory je nalezen centroid odpovídající levé komoře. Hranice endokardu jsou určeny ze znalosti polohy centroidu levé komory pomocí hranové detekce. Pro následující obraz ze série je pak referenční bod určen díky znalosti pozice centroidu předchozího snímku. [15]

Jiným postupem využívajícím obrazové vlastnosti může být využití fuzzy logiky. Pro každý pixel jsou definovány parametry charakterizující daný pixel, parametr může být závislý na samotné úrovni šedi pixelu, kdy se vychází z předpokladu, že pixely reprezentující stejné vlastnosti budou mít navzájem blízké stupně šedi. Referenční pixel reprezentující hranu je často v prvním kroku vybrán manuálně. Další parametr lze určit z konvoluce obrazu s hranovým detektorem, pixely reprezentující hrany budou operátorem zvýrazněny. Třetím parametrem může být znalost, zda byl pixel na předchozím snímku součástí hrany či nikoliv. Pro každý parametr je následně vytvořena fuzzy množina odkazující na to, s jakou velkou mírou pravděpodobnosti je daný pixel součástí kontury. Hranice endokardu je hledána vždy jako ideální spojnice mezi dvěma možnými body. [20]

2.3.2 Metody segmentace založené na pixelových vlastnostech

Segmentační metody vycházející z vlastností pixelů snímku lze nejčastěji využít, když je k dispozici větší množství snímků jedné scény, například snímky pořízené pomocí multispektrálního CT, či multimodálním zobrazováním. Nasnímaná data jsou ve většině případů šedotónové, každý voxel (pixel) scény lze zařadit do jedné z předem definovaných tříd. Obraz je tak pomocí klasifikátoru rozdělen do oblastí skládajících se z pixelů, které mají podobné hodnoty. Na tuto klasifikaci lze využít jak metody učení bez učitele, tak s učitelem. Jedna z výhod těchto přístupů je, že nepotřebují interakci uživatele. Ze skupiny metod učení bez učitele lze uvést jako příklad Gaussian Mixture Model a shlukovací metody. [9]

V případě použití Gaussian Mixture Model je snaha proložit histogram součtem několika Gaussovských křivek. Počet aproximujících křivek je parametr, který je třeba znát ze začátku. Nejčastěji se využívá dvě až pět křivek, podle typu tkání, které se ve snímku nacházejí, například srdeční svalovina, tuk a krev. Optimalizace pak probíhá pomocí Expectation - Maximization algoritmu. [21]

Při segmentačním přístupu pomocí shlukových metod dochází v prvním kroku k vyhlazení snímku z důvodu potlačení šumu, který se v obrazech nachází. Snímek je vyhlazen pomocí adaptivní filtrace, obraz je upravován jak na základě znalosti lokálních vlastností obrazu, tak i na základě odvozených statistických popisných parametrů. V takto upraveném snímku následně dojde k vytvoření několika shluků pomocí k-means shlukovacího algoritmu. Začíná se s větším množstvím nezávislých shluků, vzniklé shluky jsou postupně spojovány dohromady podle podobných vlastností. Na konci je v obraze pouze několik shluků, které už nejsou spojeny vzhledem k příliš odlišným vlastnostem. V segmentovaném obraze je poté hledána levá komora, k jejímu hledání je využito předpokládaného kruhového tvaru, tento tvar by měla na snímcích pořízených v rovině krátké osy srdeční mít. Tvar komory je aproximován na kružnici, počítá se chyba metodou nejmenších čtverců mezi konturami jednotlivých shluků a kružnicí. Kontura reprezentující levou komoru by měla mít ke kružnici nejbližší a tudíž by vypočtená chyba měla být nejnižší. [10]

2.3.3 Metody segmentace založené na deformačních modelech

Při využití metod segmentace založených na deformačních modelech se často jedná o iterativně se deformující křivky, které se snaží přizpůsobit hranicím v obraze za využití minimalizace funkce energie. Křivky jsou zároveň ovlivňovány dalšími regularizačními parametry působícími na její plynulost, pružnost. [9]

Jeden z přístupů aktivních kontur je metoda nazvaná Snakes. Jedná se o metodu, která má schopnost řešit širokou škálu problémů segmentace. Tento přístup vyžaduje určitou předchozí znalost, může se jednat například o předkreslení kontur. Snake je kontinuální spline, který je pod vlivem externích sil vycházejících z obrazu a interních sil určujících plynulost a pružnost splinu. Externí síly budou tlačit konturu směrem k výrazným obrazovým prvkům, jako jsou okraje a hrany, kontrolují přizpůsobení se obrazu. Interní síly regulují deformaci kontury, budou vycházet z předem daných hodnot, nastavených například uživatelem, nebo mohou být nastaveny na základě dřívějších pozorování automaticky. Parametricky lze pozici kontury zapsat jako

$$v(s) = (x(s), y(s)), \quad (2.10)$$

kde $x(s)$, $y(s)$ jsou jednotlivé body kontury $v(s)$ v obraze. Funkce energie kontury je daná součtem působících externích a interních sil a může být zapsána jako

$$E_{snake}^* = \int_0^1 E_{snake}(v(s)) ds = \int_0^1 (E_{internal}(v(s)) + E_{image}(v(s)) + E_{con}(v(s))) ds. \quad (2.11)$$

V této rovnici člen $E_{internal}$ reprezentuje interní energie, jejichž úkolem je regulovat deformaci křivky, E_{image} a E_{con} jsou členy, které zodpovídají za extrémní síly, které kontrolují výrazné prvky v obraze a tlačí konturu tímto směrem. E_{image} jsou energie vycházející z obrazu, E_{con} jsou síly přidávané uživatelem, může se jednat například o označení bodů, kam má být kontura přitahována či naopak odkud má být odpuzována. [22]

Při aplikaci tohoto postupu je v prvním kroku originální obraz často filtrován Gaussovskou funkcí,

$$f(x, y) = -G_\sigma(x, y) * I(x, y), \quad (2.12)$$

kde G_σ představuje 2D Gaussovskou funkci o směrodatné odchylce σ a $I(x, y)$ je originální obraz. Hodnota směrodatné odchylky určuje, jak moc bude potlačován šum v obraze, zároveň ale bude také docházet k rozmazávání hran, je proto potřeba ji volit tak, aby byl šum v obraze potlačen, zároveň zůstaly zachovány hrany a jejich vliv se rozšířil do okolí. Z filtrovaného obrazu je následně vypočtena hranová mapa jako

$$f(x, y) = -|\nabla[G_\sigma(x, y) * I(x, y)]|^2. \quad (2.13)$$

Zde je gradientní operátor reprezentován pomocí ∇ . Z matice hranových potenciálů jsou získány vektory externích sil:

$$F_{ext} = -\nabla f(x, y). \quad (2.14)$$

Na základě znalosti polohy kontury z předchozí iterace jsou vždy z gradientního pole brány hodnoty externích sil do následující iterace. Postupně tak probíhá kontinuální výpočet kontury adaptující se na hrany přítomné v obraze. Pohyb kontury se řídí rovnicí

$$X(t+1) = (I + step \cdot A) \cdot (X(t) + step \cdot W \cdot F_{ext}), \quad (2.15)$$

kde $X(t+1)$ jsou nově vypočtené body kontury, $X(t)$ jsou body kontury v předchozí iteraci, I je jednotková matice, $step$ je krok, s jak velkým dochází k postupu, F_{ext} jsou externí síly získané z mapy gradientního pole a A je matice interních sil vypočtená ze zadaných parametrů α a β , tyto parametry jsou většinou zadány dopředu

uživatelé a W , parametr váhující sílu externích sil, taktéž definovaný uživatelem. [17]

Klasický snake model není přitahován ke vzdáleným hranám. Pokud je kontura definována v prvním kroku uvnitř hledané kontury, bude se během iterací zmenšovat. V případě, že je hledaná kontura nejmenší v obraze, může dojít až k smrsknutí se kontury. Aby se tomuto předešlo, do výpočtu lze přidat balonkovou sílu. Balonková síla je definována inflačním faktorem, který působí na konturu zevnitř, zabraňuje tak úplnému smrsknutí do sebe a zároveň tlačí konturu ke vzdálenějším okrajům. V průběhu výpočtů je tak k externím silám získaným z mapy gradientního pole připočtena balonková síla, která je dána normálovými vektory kontury váhovanými parametrem ovlivňujícím celkový vliv balonkové síly. Ve výpočtu se projeví jako

$$F_{ext} = F_{ext} + W_{balloon} \cdot F_{balloon}, \quad (2.16)$$

kde F_{ext} jsou externí síly získané z mapy gradientního pole, $F_{balloon}$ jsou vypočtené normálové síly a $W_{balloon}$ je váha definovaná uživatelem, určuje, jak moc velký vliv bude výsledná balonková síla na konturu mít. [23]

Další rozšířenou metodou je metoda geometrických aktivních kontur, tento přístup spočívá ve vývoji kontury v čase, v závislosti na vnitřních geometrických vlastnostech obrazu. Do výpočtu jsou zahrnuty jak interní, tak externí vlastnosti ze zájmového regionu. Geometrické kontury umožňují v průběhu segmentace topologické změny, jako například rozdělení se na více kontur, nebo naopak spojení se z více kontur do jedné. [24]

K přístupu segmentace pomocí aktivních kontur lze přidat ještě další externí sílu, která je odvozená z hranové reprezentace obrazu, nazývá se Gradient Vector Flow (GVF). Výhoda tohoto přístupu spočívá ve schopnosti přiblížení se hranicím dutin, zároveň nepotřebují předchozí znalost, zda se mají smršťovat nebo roztahovat, aby dosáhly hranic. Jedná se tak o rozšíření klasického segmentačního přístupu pomocí Snakes, kdy se využívá gradientní pole k definování pohybu kontury. V samotném výpočtu je pak GVF začleněn do tradičního modelu snakes. [25]

U využití deformačních modelů lze při znalosti referenčního tvaru modelu být využitý další člen, který přidává anatomické omezení deformující se kontuře. Za takové omezení lze brát například vzdálenost k referenčnímu tvaru modelu, mohou odpovídat polohám zajímavých struktur. Samotná globální konzistence tvaru je pak zavedena tak, že se hledá nejmenší vzdálenost mezi řešením a prvotní znalostí vyvozené z referenčního modelu. Kontura se zarovnáva použitím kritéria, které srovná výslednou segmentaci buď k tvaru modelu, nebo k předchozímu výsledku segmentace. Segmentační postup tak musí splňovat to, že vytvořená segmentační mapa je podpořená z vizuálních pozorovatelných informací, mapa zároveň respektuje fyziologii srdce a dodržuje konzistenci tvarů s ohledem na srdeční model. [26]

2.3.4 Metody segmentace active shape a appearance models

Active shape models (ASM) jsou statistické modely tvarů objektů dané sérií bodů, které se iterativně deformují tak, aby se přizpůsobily danému obrazu. Statistický model tvaru daného objektu je získán pomocí metody analýzy hlavních komponent. Samotná segmentace se provádí umístěním modelu na obraz a iterativně se odhaduje rotace, translace a změna měřítka pomocí metody nejmenších čtverců. Zároveň se omezují váhy modelu tak, aby byly drženy i ve vhodných limitech pro podobné tvary. [27]

Active appearance models (AAM) vznikly jako rozšíření active shape models, dochází zde postupnému přizpůsobování statistického modelu tvaru a vzhledu objektům ve snímku. V prvním kroku jsou uživatelem umístěny kontury definující tvary objektů zájmu v každém trénovacím obraze. Informace o změně tvaru, která je pozorovaná v trénovacím datasetu, slouží k modelování změny tvaru. Analýza hlavních komponent je v tomto případě použita na modelování odchylek stupňů šedi v trénovacím datasetu. Výsledný model popisuje objekty ve zprůměrovaném obraze jako lineární kombinaci vlastních vektorů tvarů a stupňů šedi. [28]

Přístupy active shape models a active appearance models mohou být následně zkombinovány dohromady, využívá se toho, že zatímco active shape je vhodná spíše na nalezení lokálních struktur, active appearance funguje lépe v globálním měřítku. Jedna z možností kombinace je postupné skládání metod za sebe, v prvním kroku je provedena segmentace pomocí active appearance model, který je umístěn v obraze na srdce. Následuje zpřesnění polohy za použití kombinace obou metod a v posledním kroku je opět použit active appearance přístup, který je schopen vyvarovat se možným lokálním minimům nalezených v předchozím kroku. [29]

2.3.5 Metody segmentace založené na atlasových znalostech a registraci obrazů

Atlas popisuje různé struktury v daném typu obrazu. Může být vytvořen manuální segmentací z jednoho snímku, nebo sjednocením informací z vícera snímků, od jednoho či více jedinců. Základním principem je registrace atlasu s označenými body na obraz, který má být segmentován. Následně je získaná transformace aplikovaná zpět na atlasovou reprezentaci pro získání finální segmentace. Díky tomu lze stejným principem segmentovat celý srdeční cyklus. Vytvoření anatomického srdečního atlasu může být založeno na segmentaci jednoho snímku, ale lze vycházet z průměrného výsledku segmentace získaného z průřezu zdravých dobrovolníků. [30]

Vytvořený atlasový model může být přizpůsoben snímku pomocí flexibilní transformace, tedy transformace, která zahrnuje elastické deformace modelu. Při použití

tohoto postupu dochází k maximalizaci míry podobnosti mezi atlasovým modelem a snímkem, který je snaha segmentovat. Vzhledem k tomu, že atlasový model a snímek mohou mít nekorespondující úrovně šedi mezi sebou, je nutné vycházet pouze ze vzájemných statistických závislostí. V tomto případě se často využívá normalizovaná vzájemná informace. Samotná maximalizace podobnostního kritéria není dostatečná, toto lze řešit například přidat k podobnostnímu kritériu regularizační člen, například model viskózní tekutiny, či přidáním statistického modelu. [9]

2.4 Hodnocení úspěšnosti segmentace

Výstupem většiny segmentačních algoritmů může černobílá maska zobrazující predikovanou oblast. Úspěšnost automatické segmentace lze poté hodnotit například na základě dříve udělané manuální segmentace. Mezi často používané metriky u obrazové segmentace se může řadit Jaccardův index či Dice koeficient.

2.4.1 Jaccardův index

Jaccardův index je jedna z velmi rozšířených, používaných a efektivních metod na zhodnocení výsledku segmentace. Jaccardův koeficient je také označován jako Intersection over Union (IoU). Lze vypočítat jako poměr překrývající se plochy segmentované masky a ground truth ku celkové ploše, kterou společně zaplní segmentovaná část a ground truth.

$$IoU = \frac{AutoSegment \cap GroundTruth}{AutoSegment \cup GroundTruth}, \quad (2.17)$$

kde *AutoSegment* je plocha označená algoritmem a *GroundTruth* je manuální segmentace určující, kde se daná oblast na snímku skutečně nachází. Jaccardův index se bude pohybovat v rozmezí 0 - 1, v závislosti na překryvu. [32]

2.4.2 Dice koeficient

Dice koeficient je velmi podobný Jaccardovu indexu, v tomto případě se jedná o podíl mezi dvojnásobkem překrývající se plochy a sumy celkového počtu pixelů označujících segmentovanou oblast jak automaticky, tak manuálně.

$$Dice = \frac{2 \cdot AutoSegment \cap GroundTruth}{AutoSegment + GroundTruth}, \quad (2.18)$$

zde je opět *AutoSegment* plocha označená automaticky a *GroundTruth* je plocha označená manuálně. Dice koeficient se bude stejně jako Jaccardův index pohybovat v

rozmezí 0 - 1.

Dice koeficient a Jaccardův index jsou velmi podobné metriky, budou tím pádem dávat i velmi podobné výsledky. [33]

2.4.3 Výpočet odchylky měření

Pro hodnocení číselných výsledků lze použít absolutní a relativní chybu měření. Jedná se o porovnání naměřených hodnot s hodnotami skutečnými. Pro porovnání lze využít absolutní a relativní chybu měření.

V případě absolutní chyby měření je výpočet proveden jako

$$Error_{abs} = |X - X_{ref}|, \quad (2.19)$$

kde X je naměřená hodnota, X_{ref} je referenční hodnota, výsledkem je rozdíl mezi těmito dvěma hodnotami.

Pro výpočet relativní chyby pak lze využít výpočtu

$$Error_{rel} = \frac{|X - X_{ref}|}{X_{ref}}, \quad (2.20)$$

kde se jedná o podíl mezi absolutní chybou měření a referenční hodnotou. [34]

3 Praktická část

Praktická část je věnována nejprve načtení a předzpracování nasnímaných dat, následuje popis segmentačního přístupu, ilustrování funkčnosti algoritmu a jeho porovnání s manuální segmentací. Ve finále je diskutován vliv fibrózy na objem levé komory a ejekční frakci.

Dataset byl pořízen na MR přístroji 9.4 T BioSpin (Bruker BioSpin MRI, Ettlinger Germany), na ÚPT. Pro měření a následné hodnocení byli zvoleni potkani, část potkanů byli zdraví jedinci, druhým byla indukována fibrózou myokardu.

Dataset obsahuje celkem 27 měření devíti potkanů. Z těchto potkanů bylo 5 fibrotických, 4 byli zdraví. Poskytnutá data obsahují pro každého celkem 3 měření, která byla vykonána v průběhu listopadu a prosince roku 2021, v rámci studie fibrózy myokardu.

Během prvního měření byli všichni potkani zdraví, následně, po tomto měření byla fibrotické skupině vyvolána myokardiální fibróza, která byla sledována v následujících dvou měřeních. Druhé měření se odehrálo po dvou týdnech od vyvolání fibrózy, třetí měření o další týden později.


Každé měření obsahuje 9 řezů a 20 time framů napříč srdečním cyklem. Každý z time framů odpovídá různým fázím srdečního cyklu, mezi nimi je vždy i měření proběhlé v systole a diastole. Data byly manuálně osegmentovaná na ÚPT, panem Ing. Jiřím Vítoušem. Manuálně osegmentovaná data jsou pouze snímky odpovídající právě systole a diastole, proto pro následnou automatickou segmentaci byly brány v potaz pouze tyto snímky. Ukázka pořízeného snímku v diastole u zdravého potkana z 14. měření je zobrazena na 3.1. (Je zachováno číslování klasické, není použita indexace dle programovacího jazyku Python.)

3.1 Programové řešení

Účelem vytvořeného programu je implementovat algoritmus, který je schopný v pořízených snímcích vysegmentovat levou komoru srdeční. Na realizaci algoritmu bylo zvoleno programovací jazyk Python (Python 3.9.7), prostředí Spyder (Spyder 5.0.5). Pro správné spuštění je třeba import knihoven *numpy*, *matplotlib*, *keyboard*, *scipy* a *scikit-image*.

Programové řešení bylo zároveň testováno v nejnovější verzi Pythonu (Python 3.9.12) a Spyderu (Spyder 5.1.5), v této verzi byl zjištěna chyba - spuštění funkce *input* neprojde. Pro tuto verzi je tak vytvořena navíc ukázková verze kódu, která tento problém obchází.

Ukázka předzpracování dat a zároveň segmentačního algoritmu pro diastolu je uvedena v odevzdaných souborech, ve složce *Finalni_verze_jeden_snimek*, skript



Obr. 3.1: Ukázka snímku pořízeného během měření zdravé skupiny potkanů, 14. měření, 4. řez

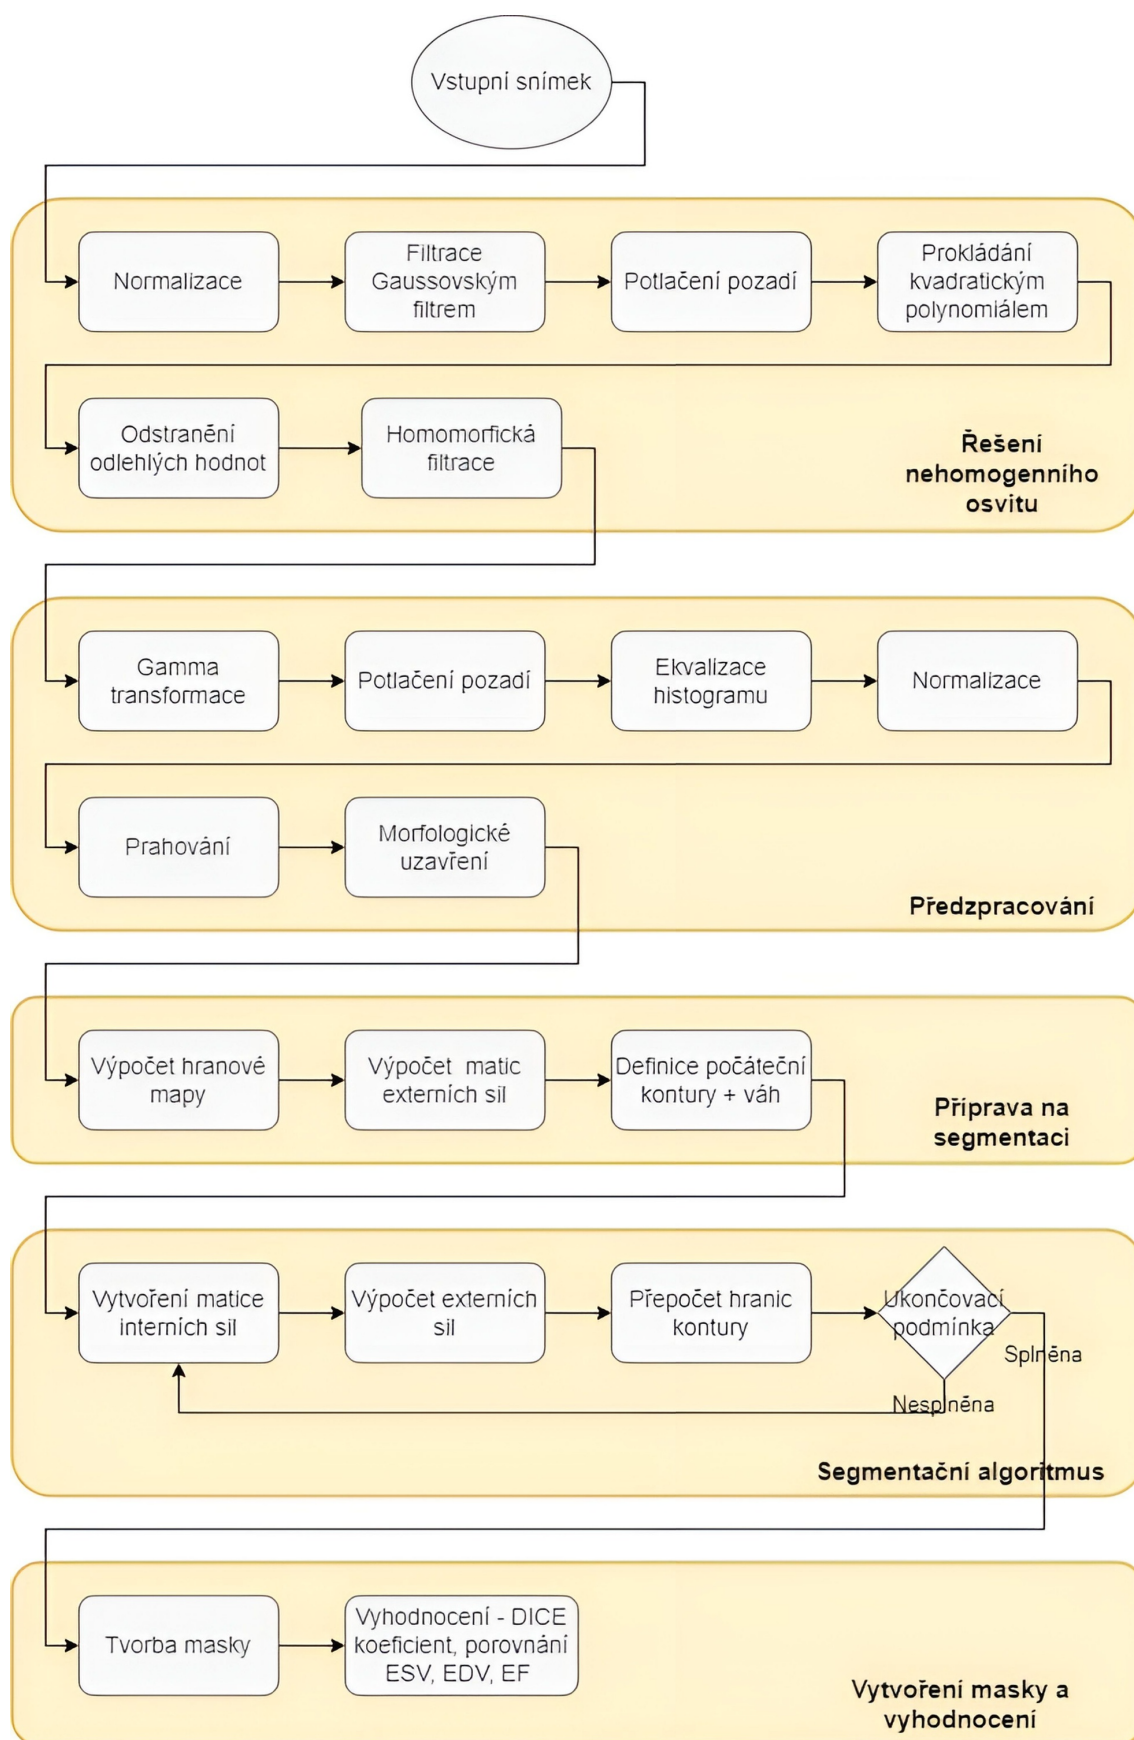
Jeden_snimek_ukazka.py. Z tohoto ukázkového kódu byly taktéž použity jednotlivé snímky zde zobrazené, vyobrazující postupné kroky algoritmu. Popis spouštění kódu je popsán níže v samostatné kapitole.

Obecný postup algoritmu je vyobrazen na vývojovém diagramu zobrazeném na 3.2.

Vývojový diagram je rozdělen do pěti větších částí, každá sestávající z několika dalších kroků. Postup je tak rozdělen na za sebou jdoucí *Řešení nehomogenního osvitu*, *Předzpracování*, *Příprava na segmentaci*, *Segmentační algoritmus* a *Vytvoření masky a vyhodnocení*. Jednotlivé kroky jsou konkrétněji popsány níže.

3.1.1 Předzpracování dat

Samotné předzpracování lze rozdělit do dvou větších bloků. V první části předzpracování dat je řešen nehomogenní osvit dat. Tato nehomogenita je patrná při porovnání intenzit pixelů reprezentujících stejný typ tkáně. Jasovou nehomogenitu lze pozorovat i na snímku 3.1, samotná srdeční svalovina obklopující levou komoru má po obvodu různý jas - blížeji u povrchu těla je intenzita pixelů mnohem vyšší, než směrem k páteři. Nehomogenní osvit obrazů je způsoben použitím povrchové snímací cívky, její citlivost klesá se vzdáleností zobrazovaných struktur od jejího povrchu. Jakmile je vyřešeno nehomogenní osvětlení, dochází k úpravě snímků tak, aby byly co



Obr. 3.2: Vývojový diagram implementovaného algoritmu

možná nejvíce zvýrazněny hrany, detaily, které budou následně konturu ovlivňovat. Ve zobrazeném vývojovém diagramu odpovídají této části bloky *Řešení nehomogenního osvitu* a *Předzpracování*.

Řešení nehomogenního osvitu

Načtený snímek je neprve normalizován, takže se všechny hodnoty nachází v rozmezí 0 - 1. Normalizace snímku je provedena pomocí vztahu 2.3, opět uveden i zde pro přehlednost.

$$I_{norm}(x, y) = \frac{I(x, y) - \min(I)}{\max(I) - \min(I)} \quad (3.1)$$

Na toto navazuje filtrace za pomoci Gaussovského filtru, nejvíce se vyplatila směrodatná odchylka $\sigma = 1.5$. Snímek je tak vyhlazen a zároveň i mírně rozostřen.


Z takto předzpracovaného snímku je následně počítaný kvadratický polynomiál, kterým je snímek vydělen, aby se vyrovnala nehomogenita osvitu. Jelikož je snaha brát v potaz pouze pixely reprezentující tkáň, nikoliv pozadí, jsou všechny hodnoty menší než polovina průměru ze snímku odstraněny. Tato hodnota byla zvolena empiricky, ve většině případů dojde k vynulování pouze pixelů pozadí. Průměrná hodnota byla zvolena z důvodu, že pixely pozadí tvoří velkou část snímku, proto bude průměrná hodnota ovlivněna právě jimi. Pixely pozadí nenesou žádnou vypovídací hodnotu využitelnou při samotné segmentaci, mohou být však nenulové z důvodu přítomnosti šumu. Snímek po těchto úpravách je vyobrazen na 3.3. Na snímku je možné pozorovat použití Gaussovského filtru, které vedlo k rozmazání snímku. Zároveň je taktéž patrné nulování nízkých hodnot, lze vidět, že velká část snímku, primárně pixely pozadí má nyní nulové hodnoty. Pro lepší zobrazení byl následujícím snímkům zachycujícím neupravené pořízené snímky lehce manuálně upraven kontrast.

V následujícím kroku je vytvořen kvadratický polynomiál, který sleduje nehomogenitu jasu ve snímku. Nejprve jsou ze snímku vybrány pouze nenulové jasové hodnoty a jim odpovídající souřadnice. Koeficienty soustavy rovnic jsou získány ze souřadnic pomocí transformace na polynom druhého stupně, ze znalosti jasových hodnot odpovídajících souřadnicím jsou dopočteny metodou nejmenších čtverců transformační koeficienty. Pro tento krok je využito rovnice 2.8, pro přehlednější orientaci v textu uvedenu i zde.

$$A \cdot X = Y \quad (3.2)$$

Přepočítání na polynom druhého stupně probíhá podle

$$A_{modifikované} = x_2 + y_2 + x \cdot y + x + y + 1, \quad (3.3)$$




Obr. 3.3: Upravený snímek po normalizaci, Gaussovské filtraci a vynulování, 14. měření, 5. řez, s manuálně upraveným kontrastem

kde x, y jsou hodnoty původních souřadnic, A jsou získané koeficienty soustavy rovnic. Podle počtu sloupců transformované matice souřadnic vyjde stejně dlouhý vektor koeficientů. V následujícím kroku jsou stejným polynomem transformovány všechny souřadnice snímku a se znalostí těchto transformačních koeficientů je následně maticovým násobením dopočten celý polynomiál, který by měl odpovídat nehomogenně rozloženému jasů ve snímku. Získaná plocha pro konkrétní snímek zobrazený na 3.3 vyobrazena na 3.4.

Je zde vidět, že polynomiál je přizpůsoben nehomogenně osvětlované oblasti, vysoké hodnoty polynomiálu se vyskytují v místech vysokého osvětlení snímku. Vzhledem k tomu, že snímek bude následně tímto polynomiálem vydělen, dojde tak k potlačení vysokých intenzit v oblastech s vyšší jasovou hodnotou a naopak v oblastech s nižší jasovou hodnotou dojde díky dělení ke zvýšení jasové intenzity.

Ve snímku se po vydělení nachází malé množství pixelů s extrémními hodnotami. Tyto pixely vznikly například vydělením vysoké jasové intenzity nízkou hodnotou prokládaného polynomiálu. Z tohoto důvodu jsou všechny hodnoty snímku nenacházející se v intervalu $\langle 0, 10 \rangle$ vynulovány. Snímek získaný po vydělení plochou je vyobrazen na 3.5.



Obr. 3.4: Vypočítaný kvadratický polynomiál použitý na proložení snímku ze 14. měření, 4. řez


Zde už je patrné, že jasové hodnoty byly globálně vyrovnány, celá oblast myokardu má již konzistentní rozložení jasových hodnot. Nevyskytují se zde velké rozdíly v intenzitách pixelů odpovídajících stejným tkáním.

Pro potlačení zbytkového nehomogenního osvitu je využito v posledním kroku vyrovnávání jasu homomorfické transformace. V prvním kroku homomorfické filtrace dochází k výpočtu logaritmu ze snímku. Z tohoto důvodu jsou všechny nulové hodnoty snímku nahrazeny nejmenší nenulovou hodnotou ve snímku se nacházející. Snímek je následně převeden do frekvenční oblasti, kde je vyfiltrován filtrem typu horní propust. Snímek by tak měl být zbaven případných zbylých nízkých frekvencí způsobujících pomalé jasové změny. Následně je potřeba transformovat snímek zpět, pomocí exponenciální funkce, inverzní k logaritmu.

Následující část předzpracování snímku se tak už věnuje samotné přípravě snímku pro segmentaci.

Předzpracování snímků pro segmentaci

Tato část algoritmu se věnuje zpracování snímku tak, aby výsledný snímek byl vhodný pro následnou segmentaci. Předzpracovaný snímek s vyrovnaným jasnem vstupuje do gamma transformace, kde je podle snímek transformován podle rov-

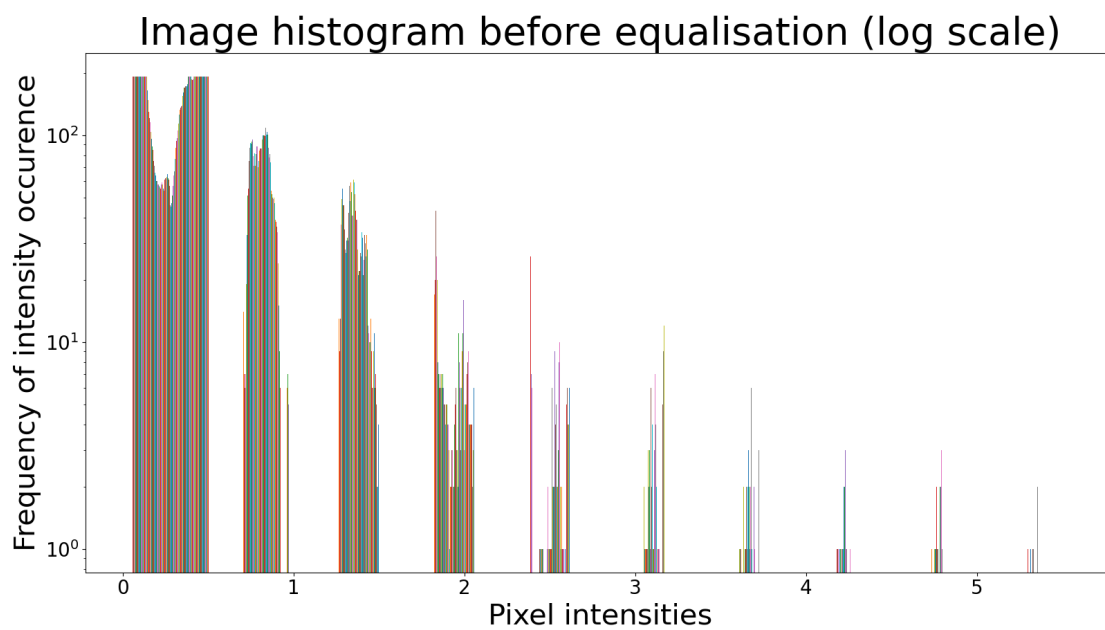


Obr. 3.5: Snímek po vyrovnání jasu pomocí proložení kvadratickým polynomiálem, 14. měření, 4. řez, s manuálně upraveným kontrastem

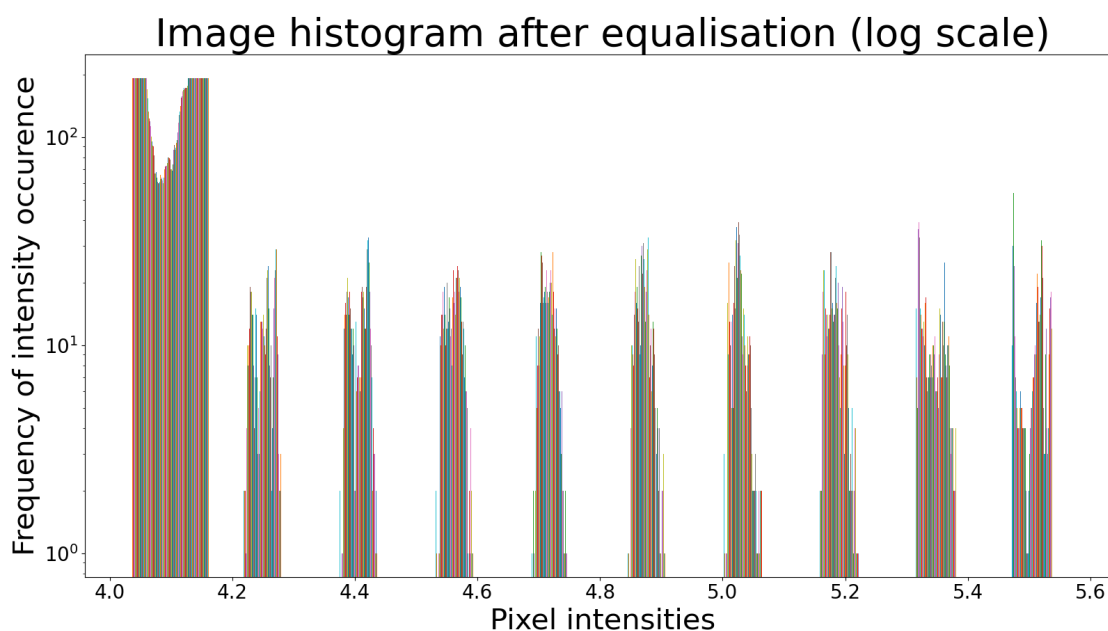
nice 2.7, pro přehlednost je opět uvedena i zde.

$$I_{transf}(x, y) = I(x, y)^\gamma, \quad (3.4)$$

Transformační konstanta γ byla zvolena $\gamma = 0.5$. Vzhledem k volbě této konstanty dojde k vyzdvihnutí rozdílů mezi vyššími jasovými hodnotami, zatímco rozdílů mezi nižšími jasovými hodnotami jsou zmírněny. Pro potlačení vysokých odlehlých hodnot, které se ve snímku mohou vyskytovat, ale nenesou žádnou informaci užitečnou pro následnou segmentaci jsou hodnoty větší než desetinásobek průměrné hodnoty nahrazeny průměrnou hodnotou. Stejně tak hodnoty blízké nule, v implementovaném algoritmu identifikované jako menší než dvojnásobek mediánu, jsou vynulovány. Tyto prahové hodnoty byly určeny na základě empirických znalostí, kdy pixely označující oblast myokardu využívaná pro následnou segmentaci tyto hodnoty neobsahuje. Následná část předzpracování má za úkol optimalizovat kontrast v obraze, aby se vyskytovaly v co možná nejširším rozmezí, se stejnou četností. Pro toto je využita ekvalizace histogramu. Ukázka rodílu mezi histogramem před ekvalizací a po ní je na vyobrazena na snímcích 3.6 a 3.7. Pro lepší viditelnost jsou histogramy uvedeny v logaritmickém měřítku.




Obr. 3.6: Histogram snímku před ekvalizací histogramu, 14. měření, 4. řez




Obr. 3.7: Histogram snímku po ekvalizací histogramu, 14. měření, 4. řez

Na histogramech je vidět rozdíl v rozložení intenzit, které se nepohybují v blízkosti nuly. Zatímco ve snímku před ekvalizací histogramu převládaly hodnoty intenzit blízké se nule, po ekvalizaci histogramu jsou tyto jasové hodnoty rozprostřeny až k maximálním jasovým hodnotám. Ve snímku by tedy měly být zvýrazněny vyšší jasové hodnoty, odpovídající právě srdečnímu myokardu. Rozdíl lze vidět i na snímku 3.8. Snímek má vyrovnaný, homogenní jas, primárně v okolí sledované levé komory, srdeční svalovina je zvýrazněna, levá komora je na snímku velmi dobře patrná a zároveň jsou pixely pozadí potlačeny.



Obr. 3.8: Snímek po ekvalizaci histogramu, 14. měření, 4. řez

Vlivem postupného předzpracování snímku se dostaly hodnoty intenzit pixelů mimo rozmezí $(0, 1)$. V následujících krocích je snaha co možná nejvíce zvýraznit levou komoru potlačením nenulových pixelů reprezentujících vnitřní oblast levé komory. Pro potlačení je použito prahování, aby bylo možno použít univerzální práh, je snímek opět převeden za pomoci normalizace do rozmezí hodnot $(0, 1)$ a ve snímku jsou vynulovány všechny hodnoty menší než průměrná hodnota snímku. Posledním krokem je aplikace morfologického uzavření na negativ snímku pro odstranění tmavých struktur. Výsledný předzpracovaný snímek, který je následně použitý v segmentačním algoritmu je vyobrazen na 3.9.



Obr. 3.9: Přezpracovaný snímek použitý pro následnou segmentaci, 14. měření, 4. řez

Snímek má v tomto kroku vyrovnané hodnoty intenzit, jas myokardu komory je zesílen oproti jasů pozadí i vnitřní části levé komory.

3.1.2 Implementovaný algoritmus

Tato část odpovídá částem *Příprava na segmentaci* a *Segmentační algoritmus* v ilustračním vývojovém diagramu na 3.2. Pro segmentaci byla zvolena metoda aktivních kontur, konkrétně metoda s názvem *snakes*. Z předpracovaného snímku je vypočtena hranová mapa podle rovnice 2.13, pro přehlednost je zde opět uvedena, s tím rozdílem, že použitý snímek již není znovu filtrován Gaussovským filtrem.

$$f(x, y) = -|\nabla[G_\sigma(x, y) * I(x, y)]|^2. \quad (3.5)$$

Ukázka získané hranové mapy je vyobrazena na 3.10. Na snímku je vidět, že levá komora je ohraničená souvislou konturou, vnitřek komory je homogenní, není zde šum, který by falešně indikoval hrany či jiné jasové přechody.

Vektory externích sil jsou následně získány na základě využití rovnice 2.14, i tato je pro lepší přehlednost opět uvedena taktéž i zde.

$$F_{ext} = -\nabla f(x, y). \quad (3.6)$$



Obr. 3.10: Hranová mapa snímku, 14. měření, 4. řez

Ve snímku je definována prvotní kontura, která se následně iterativně snaží přizpůsobit hranám v obraze, na základě vypočtených map externích sil následně dochází k ovlivňování jejího pohybu a postupným deformacím.

Řízení pohybu a tvaru aktivních kontur pro snímky reprezentující systoly se lehce liší od postupu zvoleného pro segmentaci snímků obsahujících diastoly. Různé postupy byly zvoleny z důvodu, kdy během diastoly komory většinou zabírají větší plochu z celkového snímku, je tedy vhodnější definovat někde uvnitř komory počáteční bod a konturu odvíjet od něj směrem ven. Oproti tomu během systoly je komora stažená, je tedy mnohem těžší určit centrální bod, ze kterého by kontura byla vytlačována ven. Z tohoto důvodu je naopak definována kontura jako kružnice ohraničující větší oblast a následně dochází k jejímu stahování do středu.

Algoritmus pro segmentace systol

Implementovaný algoritmus na segmentaci systol sestává z klasického přístupu metody *snakes*, kdy je prvotní kontura definována vně segmentované oblasti a postupně přitahována směrem dovnitř, kde se přizpůsobuje hranám. Pohyb kontury je tak ovlivňován pouze vypočtenými externími silami, získanými ze snímku a interními silami, definovanými uživatelem. Na počátku algoritmu je definována automaticky

kružnice, pro algoritmus je charakterizována předem definovaným středem a poloměrem.

V jednotlivých iteračních krocích dochází k přepočtu matice interních sil, její hodnoty vycházejí ze vzdáleností jednotlivých bodů kontury a hodnot definovaných uživatelem α a β . Parametr α charakterizuje kontrakční sílu kontury - čím vyšší tento parametr bude, tím víc bude kontura stahována do středu a parametr β definuje poddajnost kontury - vyšší hodnoty budou zajišťovat tuhost, kontura bude méně podléhat deformacím. Pro samotný výpočet byly pro tyto koeficienty nalezeny optimální parametry $\alpha = 2$ a $\beta = 1.5$. Parametr W , ovlivňující váhu externích sil je roven $W = 1$. Koeficient v rovnici uváděn jako *step* určuje, s jak velkým krokem se bude kontura pohybovat. Ve výpočtech byla jeho hodnota zvolena jako $\gamma = 0.2$. Na základě pozice kontury v předchozí iteraci jsou určeny hodnoty externích sil do iterace nové.

Nový bod aktivní kontury je tak v každé iteraci dopočten ze znalosti matice interních sil, externích sil, pozice kontury v předchozí iteraci a hodnot definovaných uživatelem. Vychází se z rovnice 2.15, pro přehlednost je opět uvedena i v této části.

$$X(t + 1) = (I + step \cdot A) \cdot (X(t) + step \cdot W \cdot F_{ext}) \quad (3.7)$$

Algoritmus pro segmentace diastol

Algoritmus použitý pro segmentaci diastol se liší minimálně od algoritmu implementovaného pro systolickou segmentaci. V případě diastol je využita navíc balonková síla, způsobující *nafukování* kontury. Na začátku je tak kontura definována uvnitř levé komory srdeční a vlivem nastavení parametrů, s pomocí inflační síly roztahována ven.

Prvním krokem u diastolické segmentace je opět definování kružnice, která je i v tomto případě definována předem daným středem a poloměrem, poloměr je však v tomto případě velmi malý.


Rozdílem v přístupu segmentace diastol spočívá v implementování inflační síly při získávání hodnot externích sil. V tomto případě se jejich výpočet řídí rovnicí 2.16, opět je zde pro lepší přehlednost uvedena.

$$F_{ext} = F_{ext} + W_{balloon} \cdot F_{balloon}, \quad (3.8)$$

K externím silám získaným z matic hranových potenciálů je přičítána normálová síla kontury vypočtená v jednotlivých bodech, násobená uživatelem specifikovanou konstantou, řídící vliv balonkové síly. Výpočet matice externích sil se neliší, stejně tak zůstává stejný i přepočet nových pozičních souřadnic pohybující se kontury uvedený na 2.15.

Pro segmentaci diastol jsou zvolené hodnoty parametrů odlišné od těch u systol. V tomto případě byly jako optimální parametry zvoleny hodnoty $\alpha = 0.5$, $\beta = 6$ a $W_{balloon} = 400$. Koeficienty W a γ mají stejné hodnoty, jako v případě segmentačního algoritmu, tedy $W = 1$, $\gamma = 0.2$.


V průběhu jedné iterace dochází k výpočtu vnitřní plochy kontury před aktualizací pozičních souřadnic a po ní. Rozdíl v těchto dvou plochách je vyhodnocován a na jeho základě je rozhodováno o ukončení segmentace. Pro ukončení byl stanoven práh, taktéž definovaný ve vstupních parametrech, jeho hodnota je rovna $threshold = 0.01$. Výsledek segmentačního algoritmu je uveden na 3.11.



Obr. 3.11: Výsledek segmentace levé komory během diastoly, 14. měření, 4. řez, s manuálně upraveným kontrastem

3.1.3 Ukládání masek

Výslednou segmentací je získána kontura - matice obsahující jednotlivé souřadnice. Pro výpočet objemu levé komory je však zapotřebí zjistit vnitřní plochu. V prvním kroku je vykreslena vyplněná kontura do samostatného okna, snímek je následně uložen a z uložené předpřipravené masky je vybrán indexováním přesný ořez odpovídající plochou původnímu snímku, zároveň je dbán důraz na správné umístění masky, aby její pozice odpovídala lokaci levé komory ve snímku originálním. Finální maska



Obr. 3.12: Výsledná vytvořená maska vysegmentované levé komory, bíle označena oblast levé komory, černě oblast mimo komoru, 14. měření, 4. řez

je tedy matice obsahující pouze hodnoty 0 a 1, kde 1 odpovídají pixelům umístěným uvnitř levé komory, 0 reprezentují pixely vně komory. Ukázka je uvedena 3.12.

Na základě vytvořené masky je poté provedeno hodnocení přesnosti implementovaného algoritmu. Z těchto masek jsou zároveň dopočítávány objemy komor v jednotlivých fázích srdečního cyklu, díky čemuž může být ve finále dopočtena také ejekční frakce.

3.1.4 Ukázkové skripty segmentačního algoritmu

V příložených souborech se pro ukázkou segmentačního algoritmu nachází několik ukázek, konkrétně ve složce *Finalni_verze_jedno_mereni* a ve složce *Finalni_verze_jeden_snimek*.

Složka *Finalni_verze_jeden_snimek* obsahuje skript *Jeden_snimek_ukazka*, pro jeho spuštění je třeba mít nainstalované knihovny *numpy*, *matplotlib*, *scipy* a *scikit-image*. Kód byl psán ve verzi Pythonu 3.9.7, v prostředí Spyder 5.0.5. Zároveň byl taktéž testován v novější verzi Python 3.9.12 a v prostředí Spyderu 5.1.5. Tento skript je ukázkou, jak je implementován kód postupně krok za krokem, zároveň, snímky použité v popisu algoritmu jsou generované tímto kódem. Při spuštění si

skript načítá snímek a masku (ve formátu .mat) ze stejného adresáře, během spuštění je tedy nutné mít do něj nastavenou cestu. Po jeho spuštění dojde k segmentaci snímku ze 14. měření, 4. řezu.

Ve složce *Finalni_verze_jedno_mereni* je obsaženo vícero skriptů - *Diastola_segmentation.py*, *Diastola_segmentation_keyboard.py*, *Systola_segmentation.py*, *Systola_segmentation_keyboard.py* a *Evaluation_part.py*.

Důvod, proč jsou ve složce obsaženy kódy na segmentaci systoly a diastoly dvakrát je, že novější verze programového prostředí Spyder 5.1.5 obsahuje chybu, kdy při zavolání funkce *input* dojde k pozastavení algoritmu a možnosti tuto chybu reportovat, nicméně kód jako takový neprojde. Skript *Diastola_segmentation.py* a *Systola_segmentation.py* je tak nutné spouštět ve verzi Spyderu maximálně 5.0.5, skripty *Diastola_segmentation_keyboard.py* a *Systola_segmentation_keyboard.py* jsou spustitelné jak ve verzi Spyderu 5.0.5, tak ve verzi 5.1.5. Funkce *input* je zde nahrazena funkcí *read_key* z knihovny *keyboard*.

Při spuštění jsou na začátku kódu načteny data, ze kterých vychází následná segmentace. Jedná se o ukázkové snímky, manuálně osegmentované masky a předem definované středy levých komor. Pokud je spuštěn jeden z kódů *Diastola_segmentation.py*, *Systola_segmentation.py*, je na začátku kódu nabídnuta uživateli možnost definovat vlastní centra levé komory. Přijetí či odmítnutí je řešeno zapsáním *yes* nebo *no* do příkazové řádky. V případě zvolení definice vlastních středů je následně zobrazeno několik snímků, na kterých je možné vybrat body reprezentující centra komor a tudíž i střed následně vytvořené kontury. V opačném případě jsou použity předem definované body. Na základě stanovených bodů pak proběhne samotná segmentace, na jejímž konci jsou výsledky vykresleny. Zároveň je zde pro každou segmentaci vytvořena i maska, která je porovnávána s manuální segmentací, je tak možné sledovat vyhodnocení segmentace za pomoci vypočtených dice koeficientů. Ve finální části jsou vysegmentované masky uloženy do stejného adresáře, pro ukázkou vyhodnocení v případě jednoho měření.

Při spuštění jednoho z kódů *Diastola_segmentation_keyboard.py* a *Systola_segmentation_keyboard.py* je rozhodnutí definice vlastních bodů sledováno interakcí uživatele s klávesnicí. Z tohoto důvodu je třeba mít pro tyto skripty navíc importovanou knihovnu *keyboard*. Pokud uživatel preferuje použití předem definovaných středů, stačí v průběhu běhu algoritmu zmáčknout klávesu *y*, pro definici vlastních pozic pak klávesu *n*. Zbylá část kódu se už neliší.

Na základě vysegmentovaných masek dochází k vyhodnocení přesnosti segmentace a následném hodnocení vlivu fibrózy, nicméně skripty obsahující vyhodnocení jsou diskutovány níže.

3.2 Vyhodnocení přesnosti algoritmu

Poskytnutý dataset obsahuje celkem 27 jednotlivých měření, každé měření sestává z 9 postupných řezů a 20 time framů - každé měření probíhalo v jiný okamžik během srdečního cyklu. Vzhledem k tomu, že manuálně osegmentované jsou pouze snímky reprezentující okamžik systoly a diastoly, byly z dodaného datasetu osegmentovány taktéž snímky reprezentující tuto oblast. Dalším důvodem je, že tyto okamžiky jsou z pohledu sledování vývoje end-systolického a end-diastolického objemu zajímavé, zároveň právě z těchto okamžiků jsou následně dopočítávány hodnoty sledované ejekční frakce. Ze všech 9 řezů byly pro segmentaci, hodnocení úspěšnosti segmentace a následné výpočty vybrány 3. - 7. řez. První řez a poslední dva řezy se často nacházely na hranici sledované oblasti, zároveň tyto řezy neobsahovaly manuálně osegmentované masky pro porovnání, na snímcích často nebyla levá komora patrná. Druhý řez již masky obsahoval, nicméně ne v celém rozsahu datasetu.

Pro sledování úspěšnosti segmentace, vybrání oblasti snímků odpovídajících levé komoře srdeční byl vybrán jako metrika dice koeficient.

3.2.1 Dice koeficient

Popis principu a výpočtu dice koeficientu je uveden v teoretické části diplomové práce, pro snadnější orientaci je výpočet uveden i zde.

$$Dice = \frac{2 \cdot AutoSegment \cap GroundTruth}{AutoSegment + GroundTruth}, \quad (3.9)$$

Pro každé měření bylo osegmentováno celkem 5 snímků různých řezů nasnímaných v okamžiku systoly a 5 snímků v okamžiku diastoly.

Vyhodnocení segmentace diastol

V tabulce 3.1 jsou uvedeny hodnoty základní popisné statistiky z vypočtených dice koeficientů - maximální hodnota, minimální hodnota, průměrná hodnota, medián a směrodatná odchylka. Z hodnot popisných statistik z získaných dice koeficientů je vidět, že automatická segmentace se manuální segmentaci v případě diastol velmi blíží.

Zároveň je zde i uveden graf zobrazující boxploty pro jednotlivé řezy. V grafu možné pozorovat, že první řez má vysokou variabilitu, hodnoty horního a dolního kvantilu se pohybují ve velkém rozmezí. Zároveň se zde nachází i větší množství hodnot spadajících do přesnosti segmentace pod 0.50. Tuto tendenci lze vidět i v hodnotách uvedených v tabulce 3.1. Průměrná hodnota dice koeficientu je pro první řez rovna $PrůměrDice_{řez1} = 0.69$, hodnota mediánu $MediánDice_{řez1} = 0.78$ a směrodatná odchylka je rovna $StdDice_{řez1} = 0.22$. U zbylých 4 řezů dice koeficienty

	Maximum [-]	Minimum [-]	Průměr [-]	Medián [-]	Std [-]
Řez 1.	0.95	0.21	0.69	0.78	0.22
Řez 2.	0.96	0.47	0.83	0.88	0.13
Řez 3.	0.96	0.75	0.87	0.89	0.05
Řez 4.	0.94	0.74	0.87	0.89	0.05
Řez 5.	0.94	0.50	0.85	0.86	0.08
Všechny diastoly	0.96	0.21	0.82	0.88	0.15

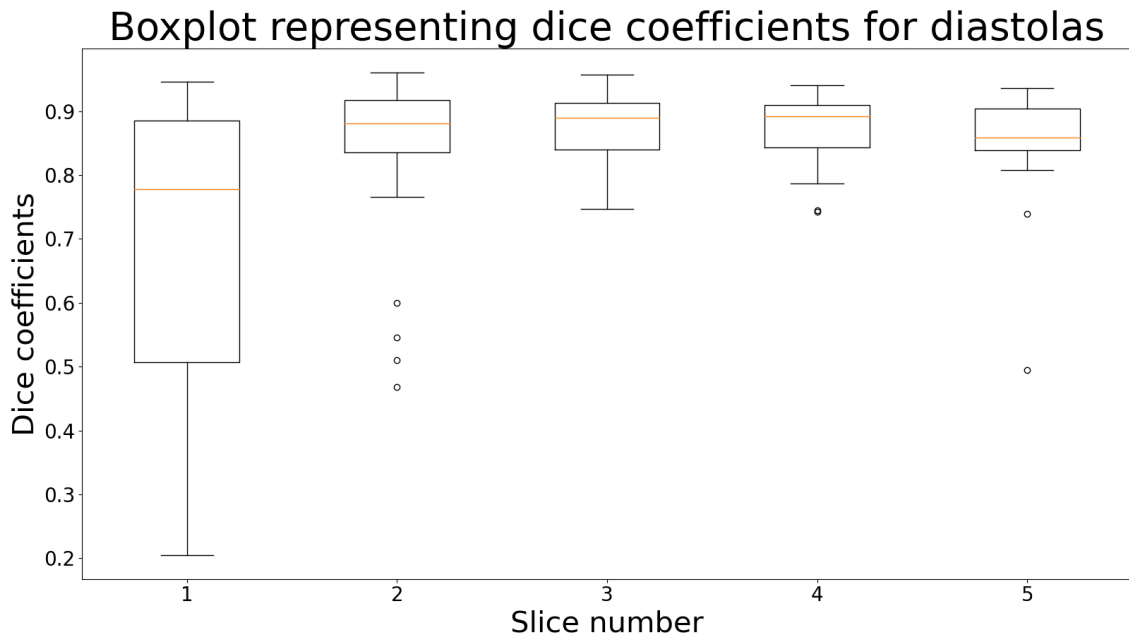
Tab. 3.1: Vypočtené hodnoty dice koeficientů v případě segmentace diastol, pro jednotlivé řezy zvlášť v řádcích, i pro všechny získané dice koeficienty, zaokrouhleno na dvě desetinná místa

ukazují vyšší úspěšnost segmentace. Průměrné hodnoty se stejně jako mediány pohybují v rozmezí 0.80 - 0.90, směrodatné odchylky jsou taktéž nižší. Z krabicového grafu uvedeného na 3.13 lze zároveň vyčíst, že v případě 2. - 5. řezu se vypočtené nízké hodnoty dice koeficientů se jedná o odlehle hodnoty. Jeden z možných důvodů nižší úspěšnosti segmentace prvního segmentovaného řezu je, že tento řez se nachází na hranici, kde se srdce může a nemusí vyskytovat, vlivem pohybu během srdečního cyklu.

Vyhodnocení segmentace systol

V obdobném duchu, jako byla vyhodnocena úspěšnost segmentace diastol byla vyhodnocena i segmentace systol. Získané hodnoty popisující dice koeficienty jsou uvedeny v tabulce 3.2. Je zde uvedena varianta pro všechny systoly a zároveň pro systoly bez 12. měření, 1. řezu. Pro tento konkrétní snímek nebyla správně určena maska, výsledný dice koeficient je tak roven $Dice_{\text{řez1}} = 0.00$. Zároveň, v případě tří měření, konkrétně měření 20., 22. a 27, nebyly na snímcích prvních řezů patrné komory. Z tohoto důvodu neměly tyto snímky ani manuálně vytvořené masky. Tyto tři snímky tak jsou úplně vyřazeny z vyhodnocení. V tabulce 3.2 jsou v řádku pojmenovaném jako *Všechny systoly bez dice < 0* uvedeny statistiky všech segmentací vyjma tří neosegmentovaných. Na následujícím řádku jsou pro porovnání uvedeny tytéž statistiky, je ale odstraněno i 12. měření. (Označení v tabulce *bez dice < 0 / bez dice <= 0* vychází z označení pozic ve výsledcích. Snímkům bez vytvořených masek byla automaticky vložena hodnota $dice = -1$. Snímek 12. měření měl výsledek $dice = 0$.)

Aby bylo možné následně vykreslit krabicové grafy, které vyžadují do každého měření stejný počet vzorků, byly hodnoty dice koeficientů odpovídající chybějícím maskám (snímky 20., 22. a 27) nahrazeny mediánovou hodnotou vypočtenou z daných řezů. Stejně tak byl nahrazen i $Dice_{\text{řez1}} = 0.00$ mediánem. Takto upravená




Obr. 3.13: Boxplot znázorňující rozložení hodnot dice koeficientů v rámci jednotlivých řezů, během segmentace diastol

data jsou následně vynesena do boxplotu zobrazeného na 3.14.

	Maximum [-]	Minimum [-]	Průměr [-]	Medián [-]	Std [-]
Řez 1.	0.88	0.00	0.49	0.50	0.24
Řez 2.	0.91	0.31	0.67	0.72	0.17
Řez 3.	0.89	0.53	0.73	0.73	0.10
Řez 4.	0.92	0.53	0.74	0.74	0.11
Řez 5.	0.89	0.46	0.70	0.72	0.10
Všechny systoly bez dice < 0	0.91	0.00	0.67	0.72	0.18
Všechny systoly bez dice <= 0	0.91	0.05	0.67	0.73	0.17

Tab. 3.2: Vypočtené hodnoty dice koeficientů v případě segmentace diastol, pro jednotlivé řezy zvlášť v řádcích, i pro všechny získané dice koeficienty, zaokrouhleno na dvě desetinná místa

Při pohledu jak na výsledné hodnoty v tabulce 3.2, tak na krabicové zobrazení na 3.14 je vidět, že segmentace systol proběhla s nižší úspěšností, než v případě segmentace diastol. Stejně tak jako v případě diastol je zde patrný trend, kdy v rámci prvního řezu jsou výsledné dice koeficienty mnohem nižší, více rozprostřené do celé škály a více nehomogenní, než v případě zbylých 4 řezů. Na rozdíl od dice koefici-




Obr. 3.14: Boxplot znázorňující rozložení hodnot dice koeficientů v rámci jednotlivých řezů, během segmentace systol

entů diastol se zde nenacházejí žádné odlehlé hodnoty, data jsou více rozprostřena. U 2. až 5. řezu je vidět, že horní a spodní kvartil dat jsou více rozprostřeny, toto je ilustrováno i uvedenými směrodatnými odchylkami v 3.2, které jsou taktéž mírně vyšší.

Obecně ale lze říci, že v případě hodnocení segmentace pomocí metriky dice koeficientů je dosaženo velmi dobrých výsledků, lepších výsledků bylo dosaženo v rámci diastol, než v rámci systol. Tento výsledek může být zapříčiněn tím, že v okamžiku diastoly je levá komora roztažená a vnitřní prostor komor na snímku zabírá velkou plochu. Naopak v okamžiku diastoly je komora stažená na mnohem menší plochu a tím pádem hůřeji identifikovatelná. Ukázka rozdílu mezi systolou a diastolou u zdravého srdce je ukázána na 3.15.

3.2.2 Možné zdroje chyb

Jak je patrné v části pojednávající o vyhodnocení úspěšnosti segmentačního algoritmu, v některých případech vytvořené masky neodpovídaly manuální segmentaci, která byla braná jako reference. K neúspěšné segmentaci mohlo dojít z vícera důvodů. V první řadě je nutné brát v potaz kvalitu snímků. Snímek z 12. měření, kde dice koeficient vyšel pro segmentaci systoly $Dice_{řez1} = 0.00$, je uveden na 3.16. Na snímku není levá komora prakticky vůbec patrná, její označení by bylo vhodné kon-




Obr. 3.15: Ukázka snímku diastoly (vlevo) a systoly (vpravo), ze 14. měření, 3. řez, s manuálně upraveným kontrastem

zultovat s odborníkem.

Mezi další možné chyby ovlivňující přesnost a úspěšnost segmentace může patřit nedokonalé předzpracování snímků, ne ve všech případech bylo ve výsledku dosaženo uzavřené komory ohraničené srdeční svalovinou, výsledný předzpracovaný snímek následně segmentovaný tak mohl vypadat například tak, jak je uvedeno na 3.17

Zde je vidět, že levá komora nebyla správně ohraničena, naopak, komora je otevřena do prostoru. Segmentační algoritmus fungující na principu postupného nafukování kontury tak bude tlačit konturu ven, za reálné hranice levé komory a výsledek segmentace tak nebude s největší pravděpodobností odpovídat manuální segmentaci.

Další možná chyba ovlivňující přesnost algoritmu je umístění počátečního středu komory - pro jednotlivá měření byl vždy určen jeden společný střed pro systoly a jeden společný pro diastoly. Střed nemusel být vhodně zvolen pro konkrétní řez, pro ostatní řezy však mohl být optimální. Tato část by se dala vyřešit manuálním umístěním středu do každého jednotlivého snímku, nicméně v rámci automatizace byla zvolena metoda společného centra na mírný úkor výsledků. Počáteční bod mohl být taktéž umístěn v nevhodně předzpracovaném snímku do oblasti světlého výběžku, jaký je pozorovatelný právě na 3.17, kontura se tudíž přizpůsobovala úplně jiným strukturám.



Obr. 3.16: Ukázka snímku s nezřetelnou levou komorou, získaného ve třetím řezu 12. měření v okamžiku systoly, s manuálně upraveným kontrastem


3.2.3 Vyhodnocení vypočtených objemů

Z vytvořených černobílých masek byly následně vypočteny hodnoty end-diaastolického a end-systolického objemu. Na základě vypočtených hodnot je dále vypočtena i hodnota ejekční frakce. Vytvořené masky jsou černobílé, kde hodnota 1 odpovídá oblasti označené jako komora, hodnota 0 je oblast mimo komoru. Masky byly sečteny a celkový součet byl následně vynásoben stanoveným objemem voxelu. Dupočítané hodnoty end-diaastolického a end-systolického objemu byly porovnány s hodnotami objemů získaných z manuální segmentace. Jednotlivé objemy byly vyneseny do krabicových grafů, následně byly taktéž dupočteny absolutní a relativní chyby měření, podle vzorců 2.19 a 2.20, opět pro přehlednost uvedeny i zde.

$$Error_{abs} = |X - X_{ref}|, \quad (3.10)$$

$$Error_{rel} = \frac{|X - X_{ref}|}{X_{ref}}. \quad (3.11)$$

Pro diastoly je výsledné porovnání vypočtených objemů vyneseno do levé části 3.18, porovnání vypočtených systolických objemů pak do pravé části 3.18. Stejně



Obr. 3.17: Ukázka špatně předzpracovaného snímku levé komory, získaného ve třetím řezu 10. měření v okamžiku diastoly

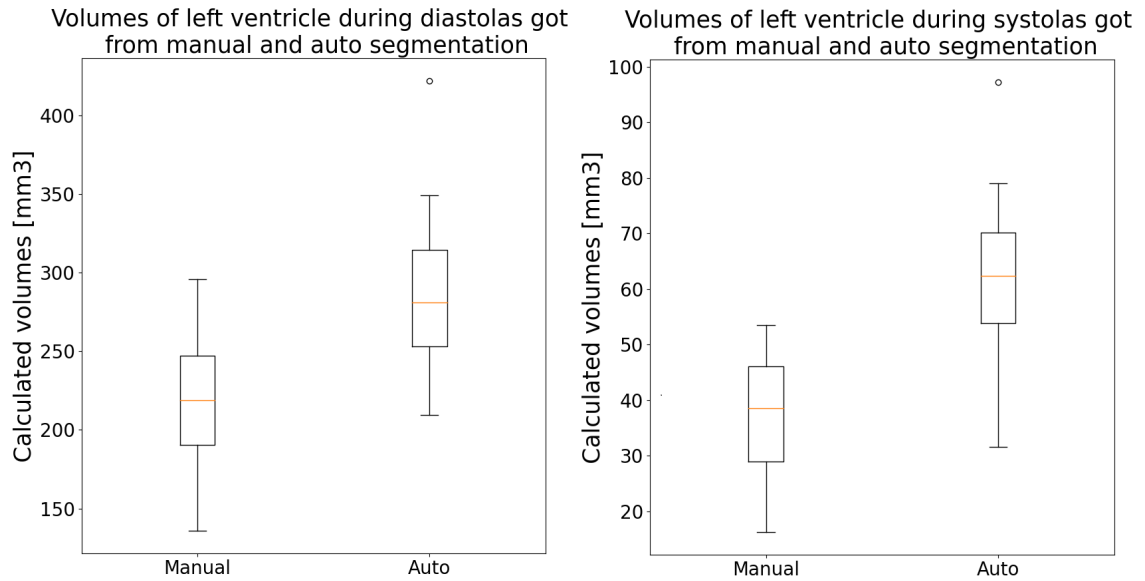
tak je zde i zobrazen krabicový graf zobrazující rozdíl mezi ejekčními frakcemi vypočtenými z manuální a automatické segmentace, 3.19.

Popisné statistiky absolutních a relativních chyb jsou vyneseny do tabulek 3.3 a 3.4.

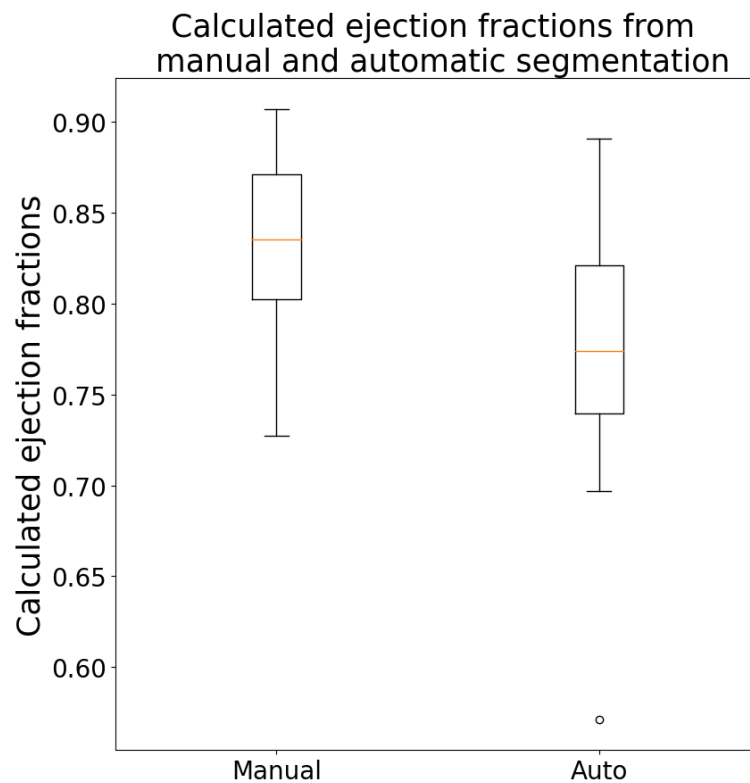
	Maximum [ml]	Minimum [ml]	Průměr [ml]	Medián [ml]	Std [ml]
$ErrorEDV_{abs}$	241.93	13.21	65.98	57.27	48.54
$ErrorESV_{abs}$	51.70	7.47	25.31	24.87	11.48
$ErrorEF_{abs}$	0.16	0.01	0.06	0.06	0.04

Tab. 3.3: Tabulka absolutních chyb pro jednotlivé vypočtené hodnoty EDV, ESV, EF

Ze znázorněných boxplotů na 3.18 je patrné, že jak v případě segmentace systol, tak v případě segmentace diastol jsou výsledné automaticky vysegmentované oblasti a tudíž vypočtené objemy vyšší, než v případě manuální segmentace. Samotný rozptyl hodnot pro manuální a automatickou segmentaci je však velmi podobný. Zvýšené objemy v případě automatické segmentace jsou patrné i z uvedených tabulek 3.3 a 3.4. Hodnoty absolutních chyb jsou zde uvedeny v absolutní hodnotě, nelze



Obr. 3.18: Boxploty znázorňující porovnání **vypočtených objemů diastoly** (vlevo) a **systoly** (vpravo) v závislosti na použité manuální / automatické segmentaci



Obr. 3.19: Boxplot znázorňující porovnání **vypočtených hodnot ejekční frakce** v závislosti na použité manuální / automatické segmentaci

	Maximum [-]	Minimum [-]	Průměr [-]	Medián [-]	Std [-]
$ErrorEDV_{relativně}$	1.34	0.07	0.34	0.27	0.29
$ErrorESV_{relativně}$	2.10	0.19	0.79	0.70	0.49
$ErrorEF_{relativně}$	0.22	0.01	0.07	0.07	0.04

Tab. 3.4: Tabulka relativních chyb pro jednotlivé vypočtené hodnoty EDV, ESV, EF


tak říct, zda maximální a minimální odchylky označují, že je objem nadhodnocený, či podhodnocený, nicméně na základě absolutních hodnot lze sledovat průměrnou hodnotu, medián a rozptyl. V případě relativních chyb je z tabulky 3.4 chybovost taktéž patrná. V případě systol je chybovost vyšší, toto je zapříčiněné tím, že levá komora je během systoly menší, tudíž posun masky o jeden sloupec vyvolá vyšší chybu, než v případě diastoly.

Pro ukázkou jsou uvedeny na 3.20 a 3.21 ukázky masek vytvořených manuální a automatickou segmentací. Horní řádek odpovídá maskám vytvořeným automatickou segmentací, spodní jsou ukázky z manuálních. Je zde vidět, že ve všech případech mají masky velmi podobný tvar, nacházejí se na stejných pozicích, v případě automatických segmentací zabírají pokaždé o trochu větší plochu, toto je patrné primárně na maskách systol.


Při pohledu na nasnímaná data je nicméně vidět, že hrana oddělující vnitřek levé komory a svalovinu myokardu není vždy úplně zřetelná, jak je například patrné na snímku 3.1. Při předzpracování může dojít k hrubšímu potlačení nezřetelných hranic, které se tím pádem posunou a výsledné segmentace budou nadhodnocené. Zároveň ale může být během manuální segmentace výsledek podhodnocen, kdy budou označeny pouze oblasti, u kterých si je člověk jistý, že do dané oblasti spadají, oblasti s nejistými hranicemi nezahrne.

Nicméně při porovnání vypočtených ejekčních frakcí je patrné, že hodnoty ejekční frakce získané pomocí manuální segmentace a automatické segmentace se na sebe velmi podobají. Při porovnání grafického zobrazení uvedeného na 3.19 je vidět, že hodnoty ejekční frakce získané manuální a automatickou segmentací jsou v podobném rozmezí hodnot. Porovnáním tabulkových hodnot je maximální rozdíl mezi automatickou a manuální segmentací roven $ErrorEF_{MaxAbs} = 0.16$ průměrná hodnota absolutní chyby je stejně jako medián roven $ErrorEF_{MeanAbs} = 0.06$, směrodatná odchylka je pak rovna $ErrorEF_{StdAbs} = 0.04$. V případě relativních chyb se i jejich hodnoty pohybují v nízkých hodnotách, indikujících vysokou podobnost mezi manuální a automatickou segmentací.

Pro účely hodnocení ejekční frakce tak lze segmentační algoritmus považovat úspěšný.



Obr. 3.20: Ukázka masek vytvořených pro snímky diastol, automatická segmentace (horní řádek) a manuální segmentace (spodní řádek). První sloupec: 5. měření, 3. řez, druhý sloupec: 14. měření, 4. sloupec, třetí sloupec: 24. měření, 3. řez



Obr. 3.21: Ukázka masek vytvořených pro snímky systol, automatická segmentace (horní řádek) a manuální segmentace (spodní řádek). První sloupec: 3. měření, 6. řez, druhý sloupec: 16. měření, 5. sloupec, třetí sloupec: 23. měření, 5. řez

3.2.4 Ukázkové skripty vyhodnocení algoritmu

Následné vyhodnocení je ukázáno pro jeden snímek skriptem *Evaluation_part.py*, umístěným ve složce *Jeden_snimek_ukazka*, primárně je ale vyhodnocení ilustrováno skriptem *Evaluation_from_contour_masks.py* umístěným ve složce *Finalni_verze_evaluation*.

Skript *Jeden_snimek_ukazka* si načítá masky vytvořené ve skriptech *Systola_segmentation.py* a *Diastola_segmentation.py*, potažmo jejich *keyboard* ekvivalentů. Z tohoto důvodu je třeba spouštět toto vyhodnocení až po projití segmentačních skriptů. Po spuštění dochází k ukázce výpočtu end-systolického objemu, end-diastolického objemu a ejekční frakce pro konkrétní měření. Zároveň se tyto hodnoty porovnávají s hodnotami získanými pomocí manuální segmentace, na základě toho jsou vypočteny taktéž chyby. Vzhledem k tomu, že se však jedná o jedno měření, není zde možnost sledovat průběh změn v rámci studie fibrózy myokardu.

Pro přesnější a kompletní vyhodnocení je určen skript *Evaluation_from_contour_masks.py*, umístěn ve třetí složce odevzdaného souboru - *Finalni_verze_evaluation*. Na začátku tohoto skriptu jsou načteny dříve vytvořené kontury jednotlivých systol a diastol pomocí segmentačních algoritmů popsanych výše. Stejně tak jsou načteny i manuálně vytvořené masky. V průběhu běhu dojde k vytvoření masek z načtených kontur, na základě masek jsou pak vypočteny dice koeficienty pro porovnání přesnosti segmentace. U tří měření, konkrétně 20, 22 a 27 nebyly manuálně osegmentovány systoly ve 3. řezu. Pro označení míst bez masky byla na pozici dice koeficientu uložena jako indikátor hodnota -1, díky tomu je možné snímky snadno odlišit. V následném hodnocení úspěšnosti segmentace byly tyto hodnoty nahrazeny mediánovou hodnotou ze všech zbylých řezů. Stejně tak byl mediánem nahrazen i první řez 12. měření.

Masky jsou konstruovány tak, že pixely odpovídající levé komoře jsou rovny hodnotě 1, oblast mimo levou komoru je označena 0. Objemy jsou pak vypočteny jako suma všech masek pro dané měření a vynásobené objemem jednoho voxelu, pro přepočítání do mm^3 . Tyto hodnoty objemů voxelů byly předem známy, byly součástí dodaného měření. Z vypočtených objemů jsou določteny hodnoty ejekční frakce, podle vzorce 2.1 uvedeného v teoretické části, pro přehlednost uvedeného i zde.

$$EF = \frac{SV}{EDV} \cdot 100 [\%] \quad (3.12)$$

SV se zde določítá jako rozdíl vypočteného end-diastolického a end-systolického objemu. Ejekční frakce může být uváděna jak v procentuální hodnotě, po vynásobení 100, tak bez ní. Ve zbylém textu bude uváděna v rozmezí 0 - 1, bez procent.

Výsledné vyhodnocení vlivu fibrózy na objem levé komory srdeční a ejekční frakce je vytvořeno na základě hodnot vypočtených v tomto skriptu.

3.3 Vyhodnocení vlivu fibrózy

Na základě automaticky vysegmentovaných oblastí, reprezentujících levou komoru v okamžiku systoly a diastoly, lze porovnat vliv fibrózy na ejekční frakci, stejně tak lze i sledovat případnou změnu v objemech komor. Pro vyhodnocení zde budou postupně zobrazovány boxploty popisující průběhy změn v objemech a v ejekčních frakcích. Uvedené grafy jsou jak pro automatickou segmentaci, tak pro manuální, pro sledování možné chyby vnesené automatizací.

Vyhodnocení vlivu fibrózy myokardu na objem levé komory

Změny objemu levé komory v průběhu studie fibrózy myokardu jsou vyneseny do grafů 3.22 - 3.25. Na těchto grafech jsou vyobrazeny krabicové grafy pro jednotlivé vypočtené end-systolické a end-diastolické objemy v rámci jednotlivých měření, pro sledovanou fibrotickou a kontrolní skupinu. Zároveň jsou vykresleny jak objemy získané automatickou segmentací, tak i manuální.

Na snímku 3.22 jsou zobrazeny vypočtené end-diastolické objemy zdravé kontrolní skupiny. V případě automatické segmentace je vidět v hodnotách mírný pokles, nicméně samotné hodnoty objemů se pohybují konstantně ve velmi podobných rozptylech, v průběhu celého měření. Pro porovnání je uveden výsledek manuální segmentace, zde je patrné, že vypočtené end-diastolické objemy se drží stále na stejné úrovni, mezi prvním a druhým měřením došlo k mírnému nárůstu. Jak bylo uvedeno dříve, v případě automatické segmentace jsou objemy mírně nadhodnocené oproti manuální.

Oproti tomu je ale na 3.23 vidět, že vlivem fibrózy došlo v průběhu měření ke změnám end-diastolických objemů. Zde je patrné, že jak v případě automatické, tak v případě manuální segmentace došlo k nárůstu end-diastolického objemu mezi prvním a druhým měřením, následně je ve třetím měření patrný pokles oproti druhému měření.

Nárůst v end-diastolických objemech je primárně patrný ve fibrotické skupině, nicméně dochází k mírnému vzrůstu i u kontrolní skupiny. Tento pomalý vzrůst může souviset s fyziologickými změnami, kdy potkani rostli, tím pádem u obou skupin docházelo mimo jiné ke zvětšování srdce. Nicméně u fibrotické skupiny docházelo zároveň k postupnému zbytnění myokardu, srdce zabírá stále stejný objem, avšak vlivem postupného ukládání extracelulární matrix se stává srdeční svalovina méně poddajná, není schopna se během diastoly tolik uvolnit, roztáhnout a tím pádem pojmout stejné množství krve jako zdravé srdce. Organismus se snaží kompenzovat vznikající deficit srdečního výdeje způsobeného vzniklou fibrózou, snaží se tedy udržet srdeční výdej tak, aby byl zachován relativně vůči objemu těla. Se zhoršující se poddajností

srdeční svaloviny však dochází k pojmnutí čím dál méně krve během diastoly a end-diastolický objem klesá. Ukázka zbytnění srdeční svaloviny je vyobrazena na 3.26, kde jsou vyobrazeny snímky získané během třetího měření na kontrolní a fibrotické skupině. Zde je nárůst myokardu u sledované fibrotické skupiny patrný - objem svaloviny obklopující levou komoru je vyšší, než v případě kontrolní skupiny.

Vypočtené end-systolické objemy kontrolní skupiny jsou opět co se hodnot týče mírně nadhodnocené v případě automatické segmentace oproti manuální, jak je vidět na 3.24. Zároveň je ale z grafů možné vyčíst, že výsledné hodnoty end-systolických objemů zůstávají ve velmi podobných hodnotách, během celého průběhu měření.


V případě fibrotické skupiny, vyobrazené na 3.25 je pak v obou postupech segmentací patrný pokles end-systolického objemu v průběhu měření.

Během postupného selhávání srdce dochází ke zhoršené srdeční činnosti, srdce není schopno tak silného stahu, tudíž by end-systolický objem neměl klesat. Zde je ale patrné, že v průběhu měření k poklesu dochází. Tento jev může být způsoben právě počáteční fází onemocnění, myokardová vlákna se stále dokážou natáhnout a vykonat stejnou práci, ne-li větší právě vlivem prvotní kompenzace onemocnění. Práce vykonaná srdeční svalovinou během systolického stahu je tak stejná, jako v případě zdravého srdce, zároveň se ale do práce vloží kompenzační mechanismy, které stah ještě o trochu více zesílí. Zároveň je srdce vlivem fibrózy zbytnělé, objem komory je menší a tudíž stejně silný stah (či lehce silnější) zapříčiní, že v okamžiku systoly bude komora stažená více a její celkový objem bude nižší, než by byl v případě zdravého srdce.


Vyhodnocení vlivu fibrózy na ejekční frakci

Na základě vypočtených end-systolických a end-diastolických objemech byla do počtena ejekční frakce pro jednotlivá měření. Vlivem myokardiální fibrózy může u sledované fibrotické skupiny docházet ze začátku k jejímu nárůstu, zatímco u kontrolní zdravé skupiny by její hodnoty neměly příliš variovat. Vypočtené hodnoty ejekčních frakcí byly rozděleny do skupin reprezentující fibrotickou a kontrolní skupinu, zároveň i do jednotlivých měření dle pořadí. Tyto hodnoty byly pro vizualizaci, porovnání a sledování možných trendů do grafů 3.27 a 3.28.

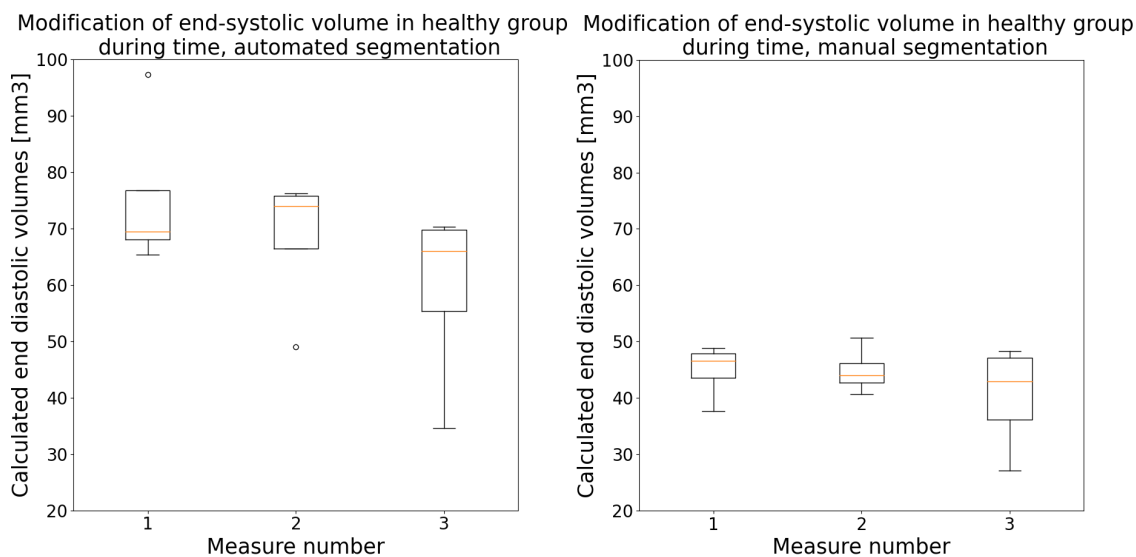
Kontrolní skupina je vyobrazena na 3.27, jak pro automatickou, tak pro manuální segmentaci. Z porovnání mezi jednotlivými metodami je vidět, že je mírný rozdíl, mezi automatickou a manuální segmentací, nicméně v průběhu celého měření je patrné, že se hodnoty ejekční frakce mění jen velmi nepatrně, drží se stále na velmi podobných hodnotách. $EF_{auto} = 0.75$, $EF_{manual} = 0.80$. Tato hodnota je blízká hodnotě udávané pro fyziologicky zdravé potkany.



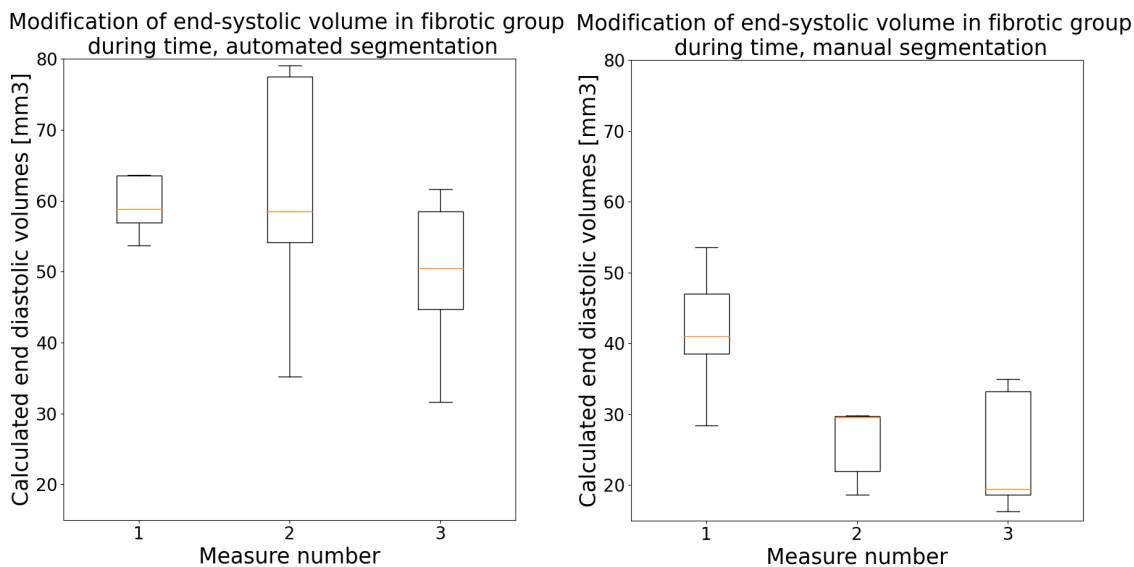
Obr. 3.22: Boxploty znázorňující získané **end-diastolické objemy u kontrolní skupiny potkanů**, v průběhu tří postupných měření, automatická segmentace (vlevo), manuální segmentace (vpravo)




Obr. 3.23: Boxploty znázorňující získané **end-diastolické objemy u fibrotické skupiny potkanů**, v průběhu tří postupných měření, automatická segmentace (vlevo), manuální segmentace (vpravo)



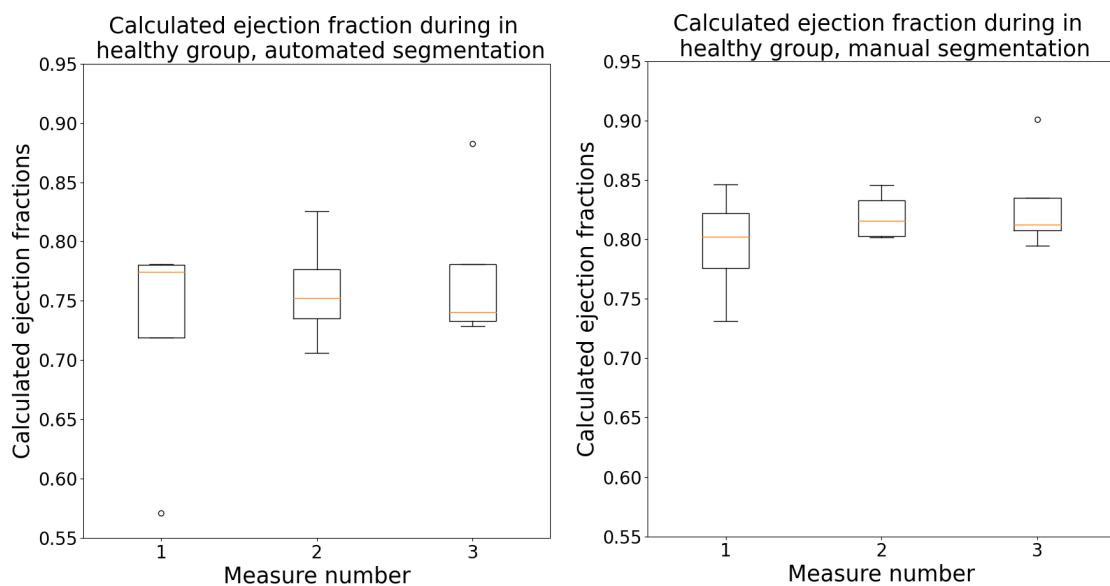
Obr. 3.24: Boxploty znázorňující získané **end-systolické objemy u kontrolní skupiny potkanů**, v průběhu tří postupných měření, automatická segmentace (vlevo), manuální segmentace (vpravo)




Obr. 3.25: Boxploty znázorňující získané **end-systolické objemy u fibrotické skupiny potkanů**, v průběhu tří postupných měření, automatická segmentace (vlevo), manuální segmentace (vpravo)



Obr. 3.26: Ukázka zbytnění myokardu vlivem indukované fibrózy u sledované fibrotické skupiny (spodní řádek) oproti kontrolní skupině (horní řádek) během třetího měření. Ukázka během diastoly (levý sloupec) a systoly (pravý sloupec), s manuálně upraveným kontrastem



Obr. 3.27: Boxploty znázorňující **vypočtené hodnoty ejekčních frakcí** v průběhu měření, **pro kontrolní skupinu**, automatická segmentace (vlevo), manuální segmentace (vpravo)



Obr. 3.28: Boxploty znázorňující **vypočtené hodnoty ejekčních frakcí** v průběhu měření, **pro fibrotickou skupinu**, automatická segmentace (vlevo), manuální segmentace (vpravo)

Oproti tomu je na následném grafu 3.28 vyobrazen postupný průběh ejekčních frakcí naměřených ve fibrotické skupině. Je zde patrný velmi vysoký nárůst mezi prvním a druhým měřením, mezi druhým a třetím měřením je již sledovatelný pokles, nicméně stále jsou tyto hodnoty ejekčních frakcí vyšší, než v případě kontrolních jedinců. Sledovaný nárůst může být způsoben vlivem právě kompenzace srdečního oslabení - v naměřených objemech je patrný vzestup end-diastolického objemu a zároveň pokles end-systolického objemu, což na vzestup vypočtené hodnoty ejekční frakce povede. Ve třetím měření je patrný pokles mediánové hodnoty vypočtených ejekční frakcí u automatické segmentace, je tedy možné, že zde už přestává působit vliv kompenzace vzniklé se začátkem vzniku fibrózy myokardu. Naopak začíná docházet vlivem vazivovatění srdečního myokardu ke snížené poddajnosti a tím pádem k postupnému poklesu ejekční frakce. V rámci měření tak lze pozorovat významný vliv myokardiální fibrózy na fungování a činnost srdce.

Na základě vyhodnocení výsledků implementované automatické segmentace vůči manuální lze algoritmus brát jako úspěšný a vhodný pro následné pozorování vlivu fibrózy na myokard. Rozdíly mezi manuální a automatickou segmentací jsou patrné na vypočtených objemech levé komory srdeční, větší rozdíl je pak pozorovaný během segmentace systol. Zároveň je ale viditelné, že rozdíl v objemech získaných manuálně a automaticky je v průřezu celé studie konzistentní, jak v případě systol, tak v případě diastol jsou výsledné objemy mírně nadhodnocené. Toto nadhodnocení by mohlo jít korigovat v předzpracování snímků, kde by se cílilo na pomalé přechody mezi komorou a srdeční svalovinou - oblasti spadající do *intervalu nejistoty* by byly zahrnuty spíše do části svaloviny, čímž by došlo ke zmenšení plochy levé komory na snímku vstupujícím do segmentačního algoritmu. Další možností jak snížit rozdíl je upravení koeficientů sil ovlivňujících kontury tak, aby byla kontura více tažena do svého nitra a méně se rozpínala. Popřípadě lze tyto metody různě kombinovat.

Následně, při sledování změn objemů komory v průběhu měření je patrný rozdíl mezi kontrolní a fibrotickou skupinou. U kontrolní skupiny nedochází k příliš velkým změnám ve vypočtených end-diastolických objemech, objemy variiují mírně, toto lze přisoudit tomu, že potkani v průběhu měření zároveň rostli. Ve výsledném porovnání tak může být zanesena chyba - sledují se zde pouze absolutní hodnoty vypočtených objemů, nikoliv objem komory vůči celkové velikosti těla potkanů. Lze tedy předpokládat, že během druhého měření je end-diastolický nárůst u fibrotické skupiny způsoben fyziologickým růstem těla, zároveň ale i snížen myokardiální fibrózou. Tento pokles však není patrný, protože není porovnání k celkové velikosti těla. U end-systolických objemů je poté patrný pokles hodnot během druhého i třetího měření. Pokles je s největší pravděpodobností zapříčiněn právě nižším objemem krve nacházejícího se v srdci během diastoly, zároveň ale stah svalu je schopen vykonat stejnou práci, takže dojde k větší kompresi během systoly a tím pádem k poklesu

end-systolického objemu.

Ve výsledku je tak i patrný vliv fibrózy na vypočtenou ejekční frakci, zatímco u zdravých potkanů se v průběhu celého měření drží na stejných hodnotách, v případě fibrotické skupiny potkanů dochází v druhém měření k prudkému nárůstu, během třetího měření je již vidět pokles. Prvotní vzestup ejekční frakce může souviset se snahou organismu kompenzovat nedostatečný srdeční výdej. Následný pokles však ukazuje, že organismus již není schopen tento výdej kompenzovat, srdeční svalovina je již velmi vazivovitá, dochází tak jak k nedostatečnému plnění komory během diastoly a tím pádem je do krevního oběhu vehnáno menší množství krve.

4 Závěr

Diplomová práce se v teoretické části zabývá srdečními onemocněními, indikátory a ukazateli onemocnění stejně tak jako možnými zobrazovacími přístupy, následně je více přiblížen i jeden z ukazatelů funkce levé komory srdeční - ejekční frakce. Následně jsou diskutovány možné metody předzpracování obrazu, na to následuje rešerše týkající se segmentačních metod často využívaných při segmentování levé komory ze snímků nasnímaných v rovině krátké osy srdeční. Nakonec jsou shrnuty i možné metriky používané na vyhodnocení přesnosti prošlých algoritmů.

V praktické části je neprve pojednáváno o předzpracování snímků tak, aby byl následně připraven na segmentační algoritmus. Předzpracování je rozděleno do dvou větších oblastí, první část se týká primárně vyrovnání nehomogenního jasu v obraze, v druhé dochází ke zvýrazňování hran. Následuje implementovaný algoritmus, který označí levou komoru ve snímku. Algoritmus byl vytvořen v programovacím jazyku Python (verze 3.9.7), v prostředí Spyder (5.0.5). Využitím vytvořeného segmentačního algoritmu byly získány kontury a následně masky označující v pořizovaných snímcích levou komoru srdeční u skupiny potkanů, kterým byla indukována myokardiální fibróza a u kontrolní skupiny potkanů. Na základě provedených segmentací jsou pak možno dopočítávány celkové objemy komor v průběhu systoly a diastoly, ze kterých vychází výpočet samotné ejekční frakce.

Na data získaná segmentací pak navazuje poslední oddíl praktické části, totiž samotné porovnání získaných end-diastolických, end-systolických objemů, ejekční frakce a změny těchto ukazatelů v průběhu studie fibrózy myokardu. Výsledky získané jak manuálně, tak automatickou segmentací jsou diskutovány.

Ze získaných výsledků je patrný vliv fibrózy na srdeční svalovinu, jejím vlivem dochází k postupnému vazivovatění myokardu, ten se stává méně poddajným a není schopen stahu jako zdravá svalovina. Tyto výsledky jsou patrné jak z vypočtených hodnot sledovaných parametrů, tak i z přiložených snímků myokardu.

Případné pokračování by se mohlo soustředit na vylepšení segmentace snímků během systoly, či na automatické určování středu levé komory srdeční.

Literatura

- [1] *World health statistics 2020: monitoring health for the SDGs, sustainable development goals*. Geneva: World Health Organization; 2020. Licence: CC BY-NC-SA 3.0 IGO
- [2] PETŘKOVÁ, Jana a Miloš TÁBORSKÝ. (Towards better definition, quantification and treatment of fibrosis in heart failure. *Cor et Vasa* [online]. 2019, 61(3), e341-e347 [cit. 2022-05-08]. ISSN 00108650. Dostupné z: doi:10.33678/cor.2019.022
- [3] HABIJAN, Marija, Danilo BABIN, Irena GALIĆ, Hrvoje LEVENTIĆ, Krešimir ROMIĆ, Lazar VELICKI a Aleksandra PIŽURICA. Overview of the Whole Heart and Heart Chamber Segmentation Methods. *Cardiovascular Engineering and Technology* [online]. 2020, 11(6), 725-747 [cit. 2021-10-28]. ISSN 1869-408X. Dostupné z: doi:10.1007/s13239-020-00494-8
- [4] Kosaraju A, Goyal A, Grigorova Y, Makaryus AN. Left Ventricular Ejection Fraction. In: *StatPearls*. StatPearls Publishing, Treasure Island (FL); 2020. PMID: 29083812.
- [5] MACEIRA, A., S. PRASAD, M. KHAN a D. PENNELL. Normalized Left Ventricular Systolic and Diastolic Function by Steady State Free Precession Cardiovascular Magnetic Resonance. *Journal of Cardiovascular Magnetic Resonance* [online]. 2006, 8(3), 417-426 [cit. 2021-10-28]. ISSN 1097-6647. Dostupné z: doi:10.1080/10976640600572889
- [6] LINDSEY, Merry L., Zamaneh KASSIRI, Jitka A. I. VIRAG, Lisandra E. DE CASTRO BRÁS a Marielle SCHERRER-CROSBIE. Guidelines for measuring cardiac physiology in mice. *American Journal of Physiology-Heart and Circulatory Physiology* [online]. 2018, 314(4), H733-H752 [cit. 2022-05-15]. ISSN 0363-6135. Dostupné z: doi:10.1152/ajpheart.00339.2017
- [7] PFEFFER, Marc A., Amil M. SHAH a Barry A. BORLAUG. Heart Failure With Preserved Ejection Fraction In Perspective. *Circulation Research* [online]. 2019, 124(11), 1598-1617 [cit. 2022-05-15]. ISSN 0009-7330. Dostupné z: doi:10.1161/CIRCRESAHA.119.313572
- [8] FOLEY, Thomas A, Sunil V MANKAD, Nandan S ANAVEKAR, Crystal R BONNICHSEN, Michael F MILLER, Todd D MORRIS a Philip A ARAOZ. Measuring Left Ventricular Ejection Fraction – Techniques and Potential Pitfalls. *European Cardiology Review* [online]. 2012, 8(2) [cit. 2021-10-31]. ISSN 1758-3756. Dostupné z: doi:10.15420/ecr.2012.8.2.108

- [9] PETITJEAN, Caroline a Jean-Nicolas DACHER. *A review of segmentation methods in short axis cardiac MR images. Medical Image Analysis [online]. 2011, 15(2), 169-184 [cit. 2021-11-23]. ISSN 13618415. Dostupné z: doi:10.1016/j.media.2010.12.004*
- [10] LYNCH, M., O. GHITA a P.F. WHELAN. *Automatic segmentation of the left ventricle cavity and myocardium in MRI data. Computers in Biology and Medicine [online]. 2006, 36(4), 389-407 [cit. 2021-11-28]. ISSN 00104825. Dostupné z: doi:10.1016/j.combiomed.2005.01.005*
- [11] SHORS, Stephanie M., Carina W. FUNG, Christopher J. FRANÇOIS, J. Paul FINN a David S. FIENO. *Accurate Quantification of Right Ventricular Mass at MR Imaging by Using Cine True Fast Imaging with Steady-State Precession: Study in Dogs. Radiology [online]. 2004, 230(2), 383-388 [cit. 2021-11-28]. ISSN 0033-8419. Dostupné z: doi:10.1148/radiol.2302021309*
- [12] RAJESHWARI, S. a T. Sree SHARMILA. *Efficient quality analysis of MRI image using preprocessing techniques. In: 2013 IEEE CONFERENCE ON INFORMATION AND COMMUNICATION TECHNOLOGIES [online]. IEEE, 2013, 2013, s. 391-396 [cit. 2022-05-08]. ISBN 978-1-4673-5758-6. Dostupné z: doi:10.1109/CICT.2013.6558127*
- [13] JAN, Jiří. *Medical image processing, reconstruction and analysis: cocepts and methods. Second edition. London: CRC Press, 2020. ISBN 978-1138310285.*
- [14] SANKUR, Bu "lent. *Survey over image thresholding techniques and quantitative performance evaluation. Journal of Electronic Imaging [online]. 2004, 13(1) [cit. 2022-05-08]. ISSN 1017-9909. Dostupné z: doi:10.1117/1.1631315*
- [15] KATOUZIAN, Amin, Ashwin PRAKASH a Elisa KONOFAGOU. *A New Automated Technique for Left- and Right-Ventricular Segmentation in Magnetic Resonance Imaging. In: 2006 International Conference of the IEEE Engineering in Medicine and Biology Society [online]. IEEE, 2006, 2006, s. 3074-3077 [cit. 2021-12-26]. ISBN 1-4244-0032-5. Dostupné z: doi:10.1109/IEMBS.2006.260405*
- [16] STARK, J.A. *Adaptive image contrast enhancement using generalizations of histogram equalization. IEEE Transactions on Image Processing [online]. 9(5), 889-896 [cit. 2022-05-08]. ISSN 10577149. Dostupné z: doi:10.1109/83.841534*

- [17] HEMALATHA, R.J., T.R. THAMIZHVANI, A. Josephin Arockia DHIVYA, Josline Elsa JOSEPH, Bincy BABU a R. CHANDRASEKARAN. *Active Contour Based Segmentation Techniques for Medical Image Analysis*. KOPROWSKI, Robert, ed. *Medical and Biological Image Analysis [online]*. InTech, 2018, 2018-07-04 [cit. 2022-01-02]. ISBN 978-1-78923-330-8. Dostupné z: doi:10.5772/intechopen.74576
- [18] FAN, Chun-Nian a Fu-Yan ZHANG. *Homomorphic filtering based illumination normalization method for face recognition*. *Pattern Recognition Letters [online]*. 2011, 32(10), 1468-1479 [cit. 2022-05-19]. ISSN 01678655. Dostupné z: doi:10.1016/j.patrec.2011.03.023
- [19] BAPAT, R.B. *Linear Algebra and Linear Models [online]*. London: Springer London, 2012 [cit. 2022-05-19]. Universitext. ISBN 978-1-4471-2738-3. Dostupné z: doi:10.1007/978-1-4471-2739-0
- [20] LALANDE, ALAIN, LOUIS LEGRAND, PAUL MICHAEL WALKER, FRANCE GUY, YVES COTTIN, SOPHIE ROY a FRANÇOIS BRUNOTTE. *Automatic Detection of Left Ventricular Contours from Cardiac Cine Magnetic Resonance Imaging Using Fuzzy Logic*. *Investigative Radiology [online]*. 1999, 34(3), 211-217 [cit. 2021-12-26]. ISSN 0020-9996. Dostupné z: doi:10.1097/00004424-199903000-00010
- [21] DEMPSTER, A. P., N. M. LAIRD a D. B. RUBIN. *Maximum Likelihood from Incomplete Data Via the EM Algorithm*. *Journal of the Royal Statistical Society: Series B (Methodological) [online]*. 1977, 39(1), 1-22 [cit. 2021-12-14]. ISSN 00359246. Dostupné z: doi:10.1111/j.2517-6161.1977.tb01600.x
- [22] KASS, Michael, Andrew WITKIN a Demetri TERZOPOULOS. *Snakes: Active contour models*. *International Journal of Computer Vision [online]*. 1988, 1(4), 321-331 [cit. 2021-12-14]. ISSN 0920-5691. Dostupné z: doi:10.1007/BF00133570
- [23] COHEN, Laurent D. *On active contour models and balloons*. *CVGIP: Image Understanding [online]*. 1991, 53(2), 211-218 [cit. 2022-01-02]. ISSN 10499660. Dostupné z: doi:10.1016/1049-9660(91)90028-N
- [24] CASELLES, Vicent, Ron KIMMEL a Guillermo SAPIRO. *Geodesic active contours*. *International Journal of Computer Vision [online]*. 22(1), 61-79 [cit. 2021-12-26]. ISSN 09205691. Dostupné z: doi:10.1023/A:1007979827043

- [25] CHENYANG XU a J.L. PRINCE. *Snakes, shapes, and gradient vector flow*. *IEEE Transactions on Image Processing* [online]. 7(3), 359-369 [cit. 2021-12-14]. ISSN 10577149. Dostupné z: doi:10.1109/83.661186
- [26] PARAGIOS, N., M. ROUSSON a V. RAMESH. *Knowledge-based registration and segmentation of the left ventricle: a level set approach*. In: *Sixth IEEE Workshop on Applications of Computer Vision, 2002. (WACV 2002)*. *Proceedings* [online]. IEEE Comput. Soc, 2002, s. 37-42 [cit. 2021-12-27]. ISBN 0-7695-1858-3. Dostupné z: doi:10.1109/ACV.2002.1182152
- [27] COOTES, T.F., C.J. TAYLOR, D.H. COOPER a J. GRAHAM. *Active Shape Models-Their Training and Application*. *Computer Vision and Image Understanding* [online]. 1995, 61(1), 38-59 [cit. 2021-12-27]. ISSN 10773142. Dostupné z: doi:10.1006/cviu.1995.1004
- [28] MITCHELL, Steven C., Boudewijn P. F. LELIEVELDT, Rob J. VAN DER GEEST, Jorrit SCHAAP, Johan H. C. REIBER, Milan SONKA a Kenneth M. HANSON. *TitleSegmentation of cardiac MR images: an active appearance model approach/title* [online]. In: . 2000-6-6, s. 224-234 [cit. 2021-12-27]. Dostupné z: doi:10.1117/12.387684
- [29] MITCHELL, S.C., B.P.F. LELIEVELDT, R.J. VAN DER GEEST, H.G. BOSCH, J.H.C. REIVER a M. SONKA. *Multistage hybrid active appearance model matching: segmentation of left and right ventricles in cardiac MR images*. *IEEE Transactions on Medical Imaging* [online]. 20(5), 415-423 [cit. 2021-12-27]. ISSN 02780062. Dostupné z: doi:10.1109/42.925294
- [30] LORENZOVALDES, M. *Segmentation of 4D cardiac MR images using a probabilistic atlas and the EM algorithm*. *Medical Image Analysis* [online]. 2004, 8(3), 255-265 [cit. 2021-12-27]. ISSN 13618415. Dostupné z: doi:10.1016/j.media.2004.06.005
- [31] IRARRAZABAL, Pablo, Craig H. MEYER, Dwight G. NISHIMURA a Albert MACOVSKI. *Inhomogeneity correction using an estimated linear field map*. *Magnetic Resonance in Medicine* [online]. 1996, 35(2), 278-282 [cit. 2022-01-02]. ISSN 07403194. Dostupné z: doi:10.1002/mrm.1910350221
- [32] BOUCHARD, Mathieu, Anne-Laure JOUSSELME a Pierre-Emmanuel DORÉ. *A proof for the positive definiteness of the Jaccard index matrix*. *International Journal of Approximate Reasoning* [online]. 2013, 54(5), 615-626 [cit. 2022-05-08]. ISSN 0888613X. Dostupné z: doi:10.1016/j.ijar.2013.01.006

- [33] GUINDON, Bert a Ying ZHANG. *Application of the Dice Coefficient to Accuracy Assessment of Object-Based Image Classification. Canadian Journal of Remote Sensing [online]. 2016, 43(1), 48-61 [cit. 2022-05-08]. ISSN 0703-8992. Dostupné z: doi:10.1080/07038992.2017.1259557*
- [34] PARK, Heungsun a L.A. STEFANSKI. *Relative-error prediction. Statistics and Probability Letters [online]. 1998, 40(3), 227-236 [cit. 2022-05-19]. ISSN 01677152. Dostupné z: doi:10.1016/S0167-7152(98)00088-1*