

Segmentační model pro predikci hojení kostí z RTG obrazů

A Segmentation Model for Bone Healing Prediction from X-ray Images

Tadeáš Blokscha

Bakalářská práce

Vedoucí práce: Ing. Jan Kubíček, Ph.D

Ostrava, 2023

Zadání bakalářské práce

Student:

Tadeáš Blokscha

Studijní program:

B0714A060016 Biomedicínská technika

Téma:

Segmentační model pro predikci hojení kostí z RTG obrazů
A Segmentation Model for Bone Healing Prediction from X-ray Images

Jazyk vypracování:

čeština

Zásady pro vypracování:

1. Nastudování základních fyzikálních principů RTG zobrazování.
2. Analýza problematiky fraktur kostí z RTG obrazů a jejich dynamiky hojení.
3. Rešerše metod identifikace kostí a fraktur z RTG obrazů.
4. Tvorba datové báze RTG dat fraktur variabilních kostí.
5. Návrh a implementace segmentačního modelu pro identifikaci kostí z RTG obrazů.
6. Návrh metod extrakce příznaků pro dynamické hodnocení hojení kostí.
7. Analýza dynamiky procesu hojení kostí na základě navrženého modelu.
8. Vyhodnocení výsledků práce.

Seznam doporučené odborné literatury:

[1] NURUZZAMAN, Mohammad. Digital image fundamentals in MATLAB. Bloomington: AuthorHouse, c2005. ISBN 1-4208-6965-5.

[2] BIRKFELLNER, Wolfgang. Applied medical image processing: a basic course. 2nd ed. Boca Raton: CRC Prress, c2014. ISBN 978-1-4665-5557-0.

[3] GILAT, Amos. MATLAB: an introduction with applications. 3rd ed. Hoboken: Wiley, c2008. ISBN 978-0-470-10877-2.

[4] MCANDREW, Alasdair. Introduction to digital image processing with MATLAB. Boston: Thomson Course Technology, c2004. ISBN 0-534-40011-6.

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí bakalářské práce: **Ing. Jan Kubíček, Ph.D.**

Datum zadání: 01.09.2021

Datum odevzdání: 30.04.2023

Garant studijního programu: prof. Ing. Martin Augustynek, Ph.D.

V IS EDISON zadáno: 16.11.2022 08:15:57

Poděkování

Rád bych poděkoval panu Ing. Janu Kubíčkoví, Ph. D., za odbornou pomoc a konzultaci při vytváření této bakalářské práce.

Abstrakt

Tato práce se zaměřuje na vytvoření modelu pro predikci hojení kostí z RTG obrazů. V teoretické části práce jsou vysvětleny základní principy RTG snímků a jak se z nich dají analyzovat zlomeniny kostí. Také jsou zde popsány různé způsoby, jak rozdělit snímek na jednotlivé části. V praktické části práce byly vytvořeny dva datasety obsahující RTG snímky zlomených kostí. Poté byl vytvořen segmentační model, který dokáže odlišit zlomeniny od pozadí na základě adaptivního prahování a aktivních kontur. Byla provedena analýza výsledků segmentace a model byl testován pomocí Sørensen-Dice koeficientu. První dataset byl použit k porovnání jasové intenzity zlomeniny a zdravé kosti, zatímco druhý dataset byl použit k porovnání vlastností zlomeniny v průběhu času, jako je obvod, obsah a jasová intenzita. Výsledky ukázaly, že segmentační model dosahoval průměrné přesnosti 0,8861 kde 1 byl nejlepší možný výsledek. Při analýze dynamiky procesů hojení bylo zjištěno, že s časech se zvyšuje jasová intenzita fraktury společně se zmenšujícím se obvodem a obsahem fraktury.

Klíčová slova

Segmentační model; fraktura; hojení

Abstract

This thesis focuses on creating a model for predicting bone healing from X-ray images. The theoretical part of the work explains the basic principles of X-ray images and how bone fractures can be analyzed from them. It also describes different methods for dividing the image into individual parts. In the practical part of the work, two datasets containing X-ray images of broken bones were created. Then, a segmentation model was developed, which can distinguish fractures from the background based on adaptive thresholding and active contours. The results of the segmentation were analyzed, and the model was tested using the Sørensen-Dice coefficient. The first dataset was used to compare the brightness of the fracture with that of a healthy bone, while the second dataset was used to compare the properties of the fracture over time, such as perimeter, area, and brightness. The results showed that the segmentation model achieved an average accuracy of 0.8861, where 1 was the best possible result. In the analysis of the dynamics of the healing processes, it was found that the brightness intensity of the fracture increases over time, while the perimeter and area of the fracture decrease.

Key words

Segmentation model; bone healing; fracture

Obsah

Seznam použitých symbolů a zkratk	- 8 -
Seznam tabulek	- 8 -
Seznam grafu	- 9 -
Seznam obrázku	- 9 -
Úvod	- 11 -
1 Základní fyzikální principy RTG zobrazení	- 12 -
1.1 Rentgen	- 12 -
1.2 Rentgenové záření	- 12 -
1.3 Vznik záření	- 13 -
1.4 Rentgenka	- 14 -
1.5 Princip rentgenového zobrazovacího systému	- 15 -
1.6 Detekce RTG záření	- 16 -
1.7 Zobrazení kostí	- 16 -
2 Analýza fraktur kosti z RTG obrazu	- 17 -
2.1 Zobrazení fraktur kosti	- 17 -
2.2 Kostní denzitometrie	- 17 -
3 Metody pro identifikaci kostí a fraktur z RTG obrazů	- 19 -
3.1 Segmentace obrazu	- 19 -
3.2 Druhy segmentace	- 19 -
3.2.1 Regionálně založené metody	- 20 -
3.2.2 Segmentace na základě prahování	- 20 -
3.2.3 Metoda rostoucích regionů	- 20 -
3.2.4 Shlukování	- 21 -
3.2.5 Shlukování metodou k-středů (k-means)	- 21 -
3.2.6 Metoda rozdělení a spojení obrazu (Split and Merge)	- 22 -
3.2.7 Watersheds(přehrad)	- 22 -
3.2.8 Metody založené na detekci hran	- 23 -
3.3 Aktivní kontury	- 25 -
4 Tvorba datové báze RTG dat fraktur variabilních kostí	- 27 -
4.1 Dataset 1	- 27 -
4.2 Dataset 2	- 28 -

5	Návrh a implementace segmentačního modelu pro identifikaci kostí z RTG obrazů.	- 29 -
5.1	Předzpracování	- 30 -
5.1.1	Lineární úprava kontrastu	- 30 -
5.1.2	Mediánový filtr	- 32 -
5.2	Segmentace s cílem identifikace fraktury kostí	- 33 -
5.2.1	Morfologické operace.....	- 33 -
5.2.2	Adaptivní prahování	- 35 -
5.2.3	Separace kosti od pozadí	- 35 -
5.2.4	Úprava kontrastu separované kosti.....	- 36 -
5.2.5	Adaptivní prahování separované kosti	- 37 -
5.2.6	Aktivní kontury (hranové).....	- 37 -
5.2.7	Binární morfologické operace	- 38 -
5.2.8	Aktivní kontury (Chan-Vese).....	- 38 -
5.2.9	Separace fraktury	- 39 -
5.2.10	Výstupní data.....	- 40 -
6	Analýza výsledku segmentačního modelu	- 42 -
6.1	Jasové intenzity	- 42 -
6.2	Směrodatná odchylka a medián	- 42 -
6.3	Obvod a obsah fraktury.....	- 43 -
6.4	Vyhodnocení přesnosti segmentace	- 43 -
7	Analýza dynamiky procesu hojení kostí na základě navrženého modelu.	- 45 -
8	Vyhodnocení výsledků práce.....	- 47 -
9	Závěr	- 48 -
	Použitá literatura.....	- 50 -
	Seznam příloh.....	- 54 -

Seznam použitých symbolů a zkratek

Zkratka	Význam
SPA	Absorptimetrie jediným fotonem
DEXA	Absorptimetrie rentgenovými paprsky s dvojitou energií.
RTG	Rentgen

Symbol	Jednotky	Význam symbolu
I	A	Proud
U	V	Napětí
eV	[eV] elektron-volt	Napětí
l	[m] metr	Délka
n	[-]	Počet pixelů
I	[-]	Jasové rozložení pixelů

Seznam tabulek

<i>Tabulka 1 Extrakce objektů z obrazu na základě binární masky</i>	- 36 -
<i>Tabulka 2 Jasové intenzity fraktury a zdravé kosti</i>	- 42 -
<i>Tabulka 3 Směrodatná odchylka a medián fraktury</i>	- 42 -
<i>Tabulka 4 Obvod fraktury</i>	- 43 -
<i>Tabulka 5 Obsah fraktury</i>	- 43 -
<i>Tabulka 6 Pacient 1 fraktura v oblasti chodidla</i>	- 45 -
<i>Tabulka 7 Pacient 2, fraktura v oblasti ramene</i>	- 45 -
<i>Tabulka 8 Pacient 3, fraktura v oblasti paže</i>	- 45 -
<i>Tabulka 9 Výsledná tabulka pro dataset 2 (50 snímků)</i>	- 47 -

Seznam grafu

Graf 1 Porovnání jasové intenzity mezi frakturou a zdravou kostí: Zdroj vlastní.....	- 40 -
Graf 2 Porovnání jasové intenzity mezi frakturou a zdravou kostí: Zdroj vlastní.....	- 40 -
Graf 3 Rozdíl průměrných jasových intenzit mezi frakturou a zdravou kostí	- 42 -
Graf 4 Přesnost segmentace fraktury.....	- 44 -

Seznam obrázku

Obrázek 1 První RTG snímek vytvořen Wilhelmem Conradem Roentgenem [34]	- 12 -
Obrázek 2 Vznik brzdného RTG záření [38]	- 13 -
Obrázek 3 Vznik charakteristického rážení [39]	- 14 -
Obrázek 4 Popis rentgenky [45].	- 14 -
Obrázek 5 Princip RTG zobrazovacího systému: Zdroj vlastní	- 15 -
Obrázek 6 Plochý panelový detektor [44].....	- 16 -
Obrázek 7 Variabilní RTG snímky fraktur: Zdroj vlastní.....	- 16 -
Obrázek 8 Příklad tří fraktur zápěstí: Zdroj vlastní.....	- 17 -
Obrázek 9 Postupná degradace kostní hmoty při osteoporóze [40]	- 18 -
Obrázek 10 Příklad úplné segmentace, kde je obrázek rozdělen na dvě části, uprostřed fraktura, pravá strana zdravá kost.....	- 19 -
Obrázek 11 Příklad použití adaptivního prahování: Zdroj vlastní	- 20 -
Obrázek 12 Příklad použití K-means segmentace na RTG snímku fraktury, na pravé straně obrázku lze vidět výstup K-means segmentace, každá barva představuje jeden shluk pixelu s podobnou jasovou intenzitou: Zdroj vlastní.....	- 22 -
Obrázek 13 Princip segmentace pomocí přehrad [31]	- 23 -
Obrázek 14 Příklad použití Cannyho detektorů hran, pravá strana obsahuje výstup Cannyho detektoru po aplikaci v oblasti fraktury: Zdroj vlastní.....	- 23 -
Obrázek 15 Příklad použití aktivních kontur: Zdroj vlastní.....	- 26 -
Obrázek 16 RTG snímky fraktur zápěstí z datasetu 1: Zdroj vlastní	- 27 -
Obrázek 17 Variabilní snímky kostí z datasetu 2: Zdroj vlastní	- 28 -
Obrázek 18 Diagram pro návrh segmentačního modelu: Zdroj vlastní.....	- 29 -
Obrázek 19 Extrahované ROI: Zdroj vlastní.....	- 30 -
Obrázek 20 Levá strana obrázku obsahuje histogram před lineární úpravou, pravá strana obsahuje histogram po úpravě.....	- 31 -
Obrázek 21 Úprava kontrastu, horní část obsahuje obrázky před úpravou kontrastu, dolní část obsahuje obrázky po úpravě kontrastu: Zdroj vlastní	- 31 -
Obrázek 22 Mediánový filtr 3x3, Horní část obrázku obsahuje RTG snímky před aplikací filtru, spodní část obsahuje data po aplikaci filtru: Zdroj vlastní.....	- 32 -
Obrázek 23 Dilatace se strukturálním elementem tvaru disk velikosti 4, horní část obrázku obsahuje RTG snímky před aplikací dilatace, spodní část obrázku obsahuje výsledek dilatace: Zdroj vlastní	- 34 -

Obrázek 24 Eroze se strukturálním elementem tvaru disk velikost 3, horní část obrázku obsahuje obrázek před erozí, dolní část obrázku obsahuje RTG snímky po erozi: Zdroj vlastní	- 34 -
Obrázek 25 Prahování otsu metodou na základě histogramu obrázku: Zdroj vlastní.....	- 35 -
Obrázek 26 Separovaná kost: Zdroj vlastní	- 36 -
Obrázek 27 Úprava kontrastu, Levá strana obrátku obsahuje 9 neupravených kostí, pravá strana obrázku obsahuje kosti po úpravě: Zdroj vlastní	- 36 -
Obrázek 28 Adaptivní prahování + Dilatace, Levá strana obsahuje výstup adaptivního prahování s citlivostí 0.62, Pravá strana obsahuje výstup dilatace: Zdroj vlastní	- 37 -
Obrázek 29 Aktivní kontury s 10 interacemi+binární inverze, levá strana obsahuje aktivní kontury, pravá strana obsahuje binární inverzi: Zdroj vlastní	- 37 -
Obrázek 30 Eroze se strukturálním elementem tvaru disk o velikosti 4, pravá strana obrázku obsahuje dilataci se strukturálním elementem o velikosti 3: Zdroj vlastní	- 38 -
Obrázek 31 Aktivní kontury „Chan-Vese“, na levé straně se nachází binární masky před aplikací aktivních kontur, na pravé straně se nachází binární masky po aplikaci aktivních kontur: Zdroj vlastní ..	- 39 -
Obrázek 32 Princip separace fraktury, na levé straně snímku se nachází binární maska fraktury, uprostřed lze vidět původní obrázek, na pravé straně se nachází výstup separace.....	- 39 -
Obrázek 33 Na levé straně obrázku lze vidět separované fraktury. Pravá strana obsahuje separované kosti bez fraktur.	- 40 -
Obrázek 34 Výstup segmentačního modelu v MATLAB rozhraní	- 41 -
Obrázek 35 Porovnaná dvou binárních masek, levá část obrázku představuje manuální segmentaci, prostřední část obrázku obsahuje automatickou segmentaci, pravá část představuje fúzování segmentace s manuální maskou: Zdroj vlastní.....	- 44 -
Obrázek 36 Pacient 1, fraktura v oblasti chodidla, jedná se o fraktury s rozstupem přibližně dvou týdnů: Zdroj vlastní.....	- 45 -
Obrázek 37 Pacient 2, fraktura v oblasti ramene, jedná se o fraktury s rozstupem přibližně 1 měsíce: Zdroj vlastní	- 45 -
Obrázek 38 Pacient 3, fraktura v oblasti paže, jedná se o fraktury s rozstupem přibližně 2 měsíců: Zdroj vlastní	- 46 -

Úvod

Tato bakalářská práce se zaměřuje na vytvoření segmentačního modelu pro předpovídání hojení kostí na základě RTG obrazů. Segmentace v tomto případě znamená rozdělení obrazu na jednotlivé části, které jsou potom analyzovány samostatně. Tímto způsobem lze získat užitečné informace o jednotlivých částech kosti, což může pomoci při diagnostice a léčbě fraktur.

Teoretická část práce se zaměřuje na základní fyzikální principy RTG zobrazování a následné analýze fraktur kostí z RTG obrazů. To zahrnuje pochopení toho, jak funguje RTG technologie a jaké informace mohou být získány z RTG obrazů. Dále se práce věnuje segmentačním metodám, které se používají k rozdělení obrazu na jednotlivé části.

V praktické části práce bylo provedeno několik kroků k analýze fraktur. Nejprve byly vytvořeny dva datasety obsahující RTG obrazy kostí s různými typy fraktur. Dataset 1 obsahoval 20 304 RTG snímků fraktur zápěstí a dataset 2 obsahoval variabilní RTG snímky fraktur ramen, rukou a chodidel.

Poté byl navržen a implementován segmentační model, který měl za úkol automaticky extrahovat fraktury z obou datasetů. Segmentační model pracoval s předem zmíněnými daty a používal segmentační metody adaptivního prahování a aktivních kontur k separaci zdravé kosti od pozadí. Následně z této separované kosti byla extrahována fraktura. K extrahované fraktuře byl následně spočítán obvod, obsah a průměrná jasová intenzita.

V poslední části práce byla provedena analýza výsledků segmentace a provedeno hodnocení přesnosti segmentačního modelu. K tomuto účelu bylo provedeno porovnání mezi manuální segmentací a segmentačním modelem. Aby se určila míra podobnosti mezi těmito dvěma metodami, byl použit Sørensen–Dice koeficient. Tento koeficient vyhodnocoval podobnost výsledků na základě čísla mezi 0 a 1, přičemž nejlepší možný výsledek byl reprezentován číslem 1.

V rámci prvního datasetu byla provedena srovnávací analýza mezi jasovou intenzitou fraktury a jasovou intenzitou zdravé kosti. V případě druhého datasetu, který obsahoval variabilní RTG snímky, byly porovnávány vlastnosti fraktury v čase, jako je obvod, obsah a jasová intenzita. V závěru práce byl zhodnocen samotný segmentační model.

1 Základní fyzikální principy RTG zobrazení

Rentgen je důležitou diagnostickou metodou, která umožňuje zobrazit vnitřní strukturu lidského těla a detekovat různá onemocnění. V této kapitole je rozebráno, jak fungují RTG přístroje, jak se vytváří rentgenové záření a jak toto záření interaguje s tělesnými tkáněmi. Následně bude rozebrán RTG zobrazovací systém z čeho se skládá a jak vzniká samotný RTG obraz.

1.1 Rentgen

Elektromagnetická radiace, známá také jako rentgenové záření, je forma elektromagnetického záření, která se podobá světlu, ale má vyšší energii. Jedná se o vlnění s krátkou vlnovou délkou a vysokou frekvencí. Rentgenové záření dokáže procházet většinou objektů, včetně lidského těla, díky své vysoké průchodnosti. Nicméně, prostupnost rentgenového záření objekty závisí na jejich vlastnostech, jako je hustota a složení.

Při průchodu objektem je část rentgenového záření pohlcována, což vede k vytvoření obrazu. Tato absorpce rentgenových paprsků je základem pro vytváření rentgenových snímků, které se používají v medicíně pro diagnostiku různých zdravotních stavů.

Historie rentgenového záření sahá do roku 1895, kdy německý vědec Wilhelm Conrad Roentgen jej poprvé objevil. Při svých experimentech s průchodem rentgenového záření přes ruku vytvořil detailní obraz kosti, čímž otevřel novou éru v medicínské diagnostice. Rentgenové záření se od té doby stalo důležitým nástrojem ve zdravotnictví, umožňujícím detekci zlomenin, nádorů a dalších patologických stavů v těle [1],[33].



Obrázek 1 První RTG snímek vytvořen Wilhelmem Conradem Roentgenem [34]

1.2 Rentgenové záření


Rentgenové záření je forma elektromagnetického záření s energií obvykle mezi 1 až 500 kilo elektronvoltů (keV). Vlnová délka rentgenového záření se pohybuje v rozmezí od velmi krátkých 0,006 nanometrů do 1,25 nanometrů. Toto záření vzniká interakcí s jádry atomů, což zahrnuje změnu rychlosti nabitých částic, a také interakcí s obalovými elektrony, kdy dochází ke změně energetických hladin elektronů v atomu. Zdrojem rentgenového záření je zařízení nazývané rentgenka, která využívá elektrického napětí k urychlování elektronů. Rentgenové záření je schopno pronikat mnoha různými materiály, jako jsou tkaniny, kovy nebo kosti, a na základě své absorpce a průchodnosti

materiály se dají zobrazit na rentgenových snímcích. Absorpce rentgenového záření závisí na vlastnostech materiálu, jako je jeho hustota a složení. Díky tomu se rentgenové záření stalo neocenitelným nástrojem pro diagnostiku různých zdravotních stavů, jako jsou zlomeniny kostí, plicní onemocnění, nádory a další patologické stavy[1],[3].

1.3 Vznik záření


Rentgenové záření se dělí na dvě základní kategorie podle způsobu vzniku: brzdné rentgenové záření a charakteristické rentgenové záření

Brzdné rentgenové záření vzniká, když elektron z elektronového svazku rentgenky narazí na anodu. Při tomto střetu se elektron dostane k jádru atomu anody, a díky působení magnetického pole jádra dojde k zakřivení dráhy elektronu a následnému zbrzdění. Kinetická energie, kterou elektron ztratí při zbrzdění, je vyzářena ve formě fotonu rentgenového záření. Vlnová délka tohoto záření závisí na množství ztracené kinetické energie a pohybuje se v různém rozmezí od 0,006 nm do 1,25 nm. Díky této variabilitě vlnové délky vzniká spojité spektrum rentgenového záření [32].



Obrázek 2 Vznik brzdného RTG záření [38]


Charakteristické rentgenové záření vzniká, když elektron z elektronového svazku rentgenky střetne s atomy anody. Při tomto střetu může elektron předat energii elektronům nacházejícím se v atomech anody. To může mít za následek vyražení elektronu do vyšší energetické hladiny nebo jeho ionizaci, tedy vytržení z obalu atomu anody. Pokud dojde k ionizaci elektronu, jeho místo v obalu zaujme jiný elektron s vyšší energetickou hladinou, a tento nový elektron poté vyzáří značné množství energie ve formě fotonů rentgenového záření. Charakteristické rentgenové záření tedy vytváří specifické spektrum záření, které je charakteristické pro materiál anody [32].



Obrázek 3 Vznik charakteristického záření [39]

1.4 Rentgenka

Rentgenka může být vakuová elektroda, trubice nebo lampa. Rentgenka pracuje v obvodu s vysokým napětím (10 až 100kV). Pomocí proudu se zahřeje vlákno (katoda), toto vlákno emituje elektrony, které jsou urychlovány pomocí vysokého napětí směrem k anodě, která je přitahuje. Z jednoho procenta těchto urychlených elektronů vzniká rentgenové záření, zbytek kinetické energie je přeměněno na teplo. Díky této přeměně může rentgenka dosahovat teplot až 2500 °C, proto je zapotřebí aby rentgenka byla chlazená. Rentgenka je chlazená olejem nebo vzduchem [1].



Obrázek 4 Popis rentgenky [45].

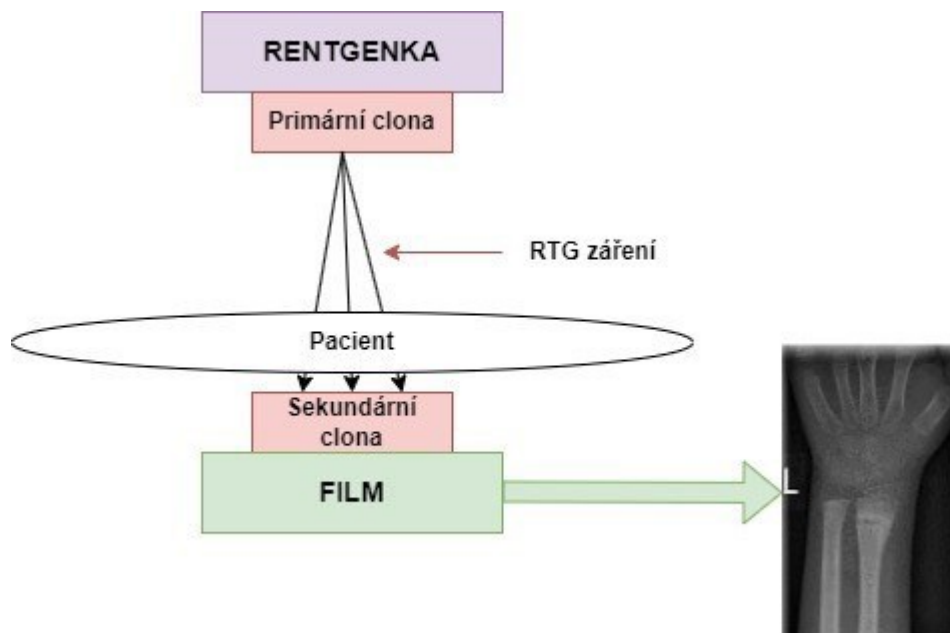
Rentgenky dělíme podle konstrukčního hlediska:

- S pevnou anodou
- S rotační anodou
- Rentgenky s rotačním krytem

Provedení rentgenky s pevnou anodou se využívají velmi zřídka. Setkat se s ní můžeme například u dentálních rentgenů. Mnohem využívanější provedení je s rotační anodou, konstrukce je podobná jako u rentgenky s pevnou anodou s rozdílem chybějícího rotačního motoru, jehož úkolem je rotovat s anodou. Rotační motor dokáže dosahovat až 20 000 otáček za minutu. U rotační anody je z důvodu rotace problém s chlazením, proto je využívána rhenium-wolfram-molybden anoda, jelikož ji lze více tepelně zatížit. Rentgenka s rotačním krytem nám eliminuje problém s chlazením a umožní generaci RTG paprsků s vysokým výkonem. U rentgenek s rotačním krytem dochází k rotaci celé trubice, což má za důsledek lepší rozložení tepla a anoda může být po celou dobu generace rentgenových paprsků chlazena [1].

1.5 Princip rentgenového zobrazovacího systému

RTG zobrazovací systém se skládá z rentgenky, dvou clon (primární a sekundární) a filmu. Nejprve dojde ke generaci RTG záření pomocí rentgenky. Ze záření je pomocí filtru odfiltrováno část záření, které obsahuje zbytečně dlouhé vlny, škodlivé pro pacienta. Následně záření prochází skrz primární clonu, která zapříčiní zúžení paprsku. Záření dále prostupuje skrz pacienta a dopadá na sekundární clonu. Sekundární clona zachytí interakci RTG záření s tkání, tato interakce je zaznamenána na kazetu s filmem, uloženou pod sekundární clonou [1],[2].



Obrázek 5 Princip RTG zobrazovacího systému: Zdroj vlastní

1.6 Detekce RTG záření

Na rentgenový film dopadá RTG záření. Díky fotografické emulzi s obsahem stříbra dochází k reakci mezi rychlými elektrony a zrnky stříbra, což zapříčiní vznik takzvaného latentního obrazu. Míru černosti obrazu nám určuje množství ozářených zrněk stříbra. Ostrost obrazu je závislá na jemnosti těchto zrněk. Výsledkem jemnějších zrněk je ostřejší obraz [1],[2].

U digitální radiografie je nejčastěji používán systém obsahující detektory s plochým panelem. Tyto detektory jsou složeny z tenkých tranzistorů a převodníku vyrobeného ze světlocitlivého materiálu. Tranzistor v detektoru představuje jeden pixel. Lze říct, že větší množství tranzistorů představuje ostřejší obraz. Výsledkem je matice intenzit záření. Tento výsledek představuje RTG paprsek navzorkován z hlediska prostoru a intenzity.



Obrázek 6 Plochý panelový detektor [44]

1.7 Zobrazení kostí

RTG paprsek při průchodu objektem naráží na různé bariéry s různou schopností absorpce. Předměty, co mají větší hustotu, tloušťku a protonové číslo absorbují více záření. Tato schopnost absorpce je v RTG snímku poté vyjádřena ve stupni šedi. U lidského těla má nejvyšší protonové číslo kost. Kost obsahuje vápník a fosfor, z tohoto důvodu dochází k vyšší absorpci záření, to se nám projevuje na obrázku světlým odstínem, oproti lidské tkáni, která absorbuje RTG záření méně.

RTG záření můžeme také využít v tzv. kostní denzitometrii. Kost vlivem osteoporózy ztrácí hustotu minerálů v kostech. To zapříčiní větší náchylnost ke zlomeninám.



Obrázek 7 Variabilní RTG snímky fraktur: Zdroj vlastní

2 Analýza fraktur kosti z RTG obrazu

Fraktury kostí jsou velmi častými poraněními, které mohou mít značný dopad na kvalitu života pacienta. Identifikace a analýza fraktur kostí jsou důležitými kroky v diagnostice a léčbě těchto poranění. Tato kapitola je zaměřena na zobrazení fraktur pomocí RTG snímků a kostní denzitometrii, která umožňuje měřit hustotu kostní tkáně a identifikovat riziko vzniku osteoporózy.

2.1 Zobrazení fraktur kosti

V RTG snímku se fraktura projevuje jako černá nebo bílá linie. U fraktury, kde došlo k odlomení části kosti, dochází v místě fraktury k malé absorpci RTG paprsku. To se nám v snímku projeví jako tmavší barva, oproti komplikovanější fraktuře, kde dojde k překrytí úlomku kostí. V místě překrytí dojde k větší absorpci paprsku tudíž ve výsledku vznikne světlejší okrasek nebo linie [10].



Obrázek 8 Příklad tří fraktur zápěstí: Zdroj vlastní

2.2 Kostní denzitometrie

V kostní denzitometrii je stanovena míra absorpce X záření pomocí RTG adsorbční fotometrie. Na základě této míry lze zjišťovat hustota kostní tkáně. U kostní denzitometrie je využito dvou metod:

SPA – Single Photon Absorptiometry

DEXA – Dual Energy X-ray Absorptiometry

V prvním případě je kost prozařovaná úzkým svazkem o jedné energii. Tato metoda je spojena s jednou nevýhodou. U této metody nelze rozlišit, zda absorpce byla způsobena kostí nebo měkkou tkání. Z tohoto důvodu vznikla dokonalejší metoda, která využívá dvou energií RTG záření. Tato metoda umožňuje rozdělit kost a měkkou tkáň. Díky této možnosti je metoda považovaná za zlatý standard. Úroveň minerální hustoty v kosti získáme [7],[8]:

$$BDM = \frac{ROI \text{ Hodnota} - \text{zachycené BMD}}{BMD \text{ gradient}} \quad (1)$$

Výsledek je poté rozdělen na 2 sekce, a to T skóre a Z skóre[9],[19].

T skóre porovnává množství kostí pacienta s mladou populací stejného pohlaví s vrcholem kostní hmoty.

$$T \text{ skóre} = \frac{(BDM \text{ pacienta} - \text{průměrné BMD mladého jedince})}{SD \text{ mladého jedince}} \quad (2)$$

Kde BDM je kostní minerální hustota a SD standartní odchylka [8].

Výsledek nad -1 je považován za standartní. Výsledek mezi -1,1 a -2,4 se považuje jako osteopenie. Jako osteoporóza je považován výsledek pod -2,5. Díky těmto výsledkům lze určit risk vzniku a také určení, zda je nutná léčba [7],[8].

Z skóre určuje množství kostí s porovnáním pacientů ve stejné věkové skupině, stejné velikosti a pohlaví.

$$Z \text{ skóre} = \frac{(BMD \text{ pacienta} - \text{Průmerné BMD pacienta stejné věkové skupiny})}{SD \text{ pacienta stejné věkové skupiny}} \quad (3)$$

Kde BDM je kostní minerální hustota a SD standartní odchylka [8].



Obrázek 9 Postupná degradace kostní hmoty při osteoporóze [40]

3 Metody pro identifikaci kostí a fraktur z RTG obrazů

Identifikace kostí a fraktur z RTG obrazů je kritickou součástí diagnostiky mnoha onemocnění a úrazů, jako jsou například osteoporóza, rakovina kostí, zlomeniny a další. Existuje mnoho různých přístupů a metod pro segmentaci kostí a fraktur z RTG obrazů, které se liší podle použitého algoritmu, přístupu k segmentaci a dalších faktorů.

V této kapitole budou popsány různé druhy metod pro identifikaci kostí a fraktur z RTG snímku společně s výhodami a nevýhodami

3.1 Segmentace obrazu

Segmentace je proces rozdělení obrázku na několik částí, které mají za cíl představovat jednotlivé části reálného světa. Existují dva základní typy segmentace – úplná a částečná.

Úplná segmentace zahrnuje rozdělení obrazu do oblastí, které přímo odpovídají objektům nacházejícím se v obraze. To znamená, že jednotlivé části obrázku jsou identifikovány a odděleny na základě skutečných objektů, které se v obraze nacházejí. Úplná segmentace je často používána, když je potřeba získat přesné informace o jednotlivých objektech v obraze, jako například detekce objektů v medicínských snímcích nebo rozpoznávání objektů v autonomních vozidlech [4].

Naopak částečná segmentace se provádí na základě předem definovaných vlastností, jako je například jas nebo barva, a neodpovídá objektům přímo v obraze. Obraz je rozdělen do oblastí na základě těchto definovaných vlastností, které nemusí přesně odpovídat skutečným objektům v obraze. Výsledky z částečné segmentace mohou být použity jako vstup pro další zpracování obrazu na vyšší úrovni, například pro analýzu obrazových dat nebo pro rozpoznávání vzorů [4].

Oba typy segmentace mají své výhody a nevýhody a jsou používány v různých aplikacích podle konkrétních potřeb a požadavků zpracování obrazu. Úplná segmentace je více přesná, ale náročnější na výpočetní prostředky a čas. Částečná segmentace je rychlejší, ale může mít nižší přesnost, zejména v komplexních scénách [4].



Obrázek 10 Příklad úplné segmentace, kde je obrázek rozdělen na dvě části, uprostřed fraktura, pravá strana zdravá kost

3.2 Druhy segmentace

Existuje několik druhů segmentace. Blokované metody segmentace jsou založeny na rozdělení obrazu do různých bloků nebo regionů na základě určitých kritérií. Existuje několik různých přístupů v rámci blokované segmentace, z nichž dva hlavní jsou regionální metody a metody detekce bodů a hran.

3.2.1 Regionálně založené metody


Regionální metody segmentace se zaměřují na identifikaci a oddělení oblastí v obraze na základě podobnosti mezi sousedícími pixely. Tyto metody se pokouší najít souvislé oblasti s podobnými vlastnostmi, jako je například barva, jas, textura nebo kontrast, a oddělit je od okolních oblastí. Regionální metody jsou často používány pro segmentaci objektů s jednotným pozadím, jako například na fotografii nebo ve videu.

3.2.2 Segmentace na základě prahování

Prahování je jedna z nejstarších metod používaných pro analýzu RTG obrazů. Tato metoda je založena na principu nastavení jasového prahu, který rozlišuje objekty v obraze na základě jejich jasových hodnot. Objekty s vyššími jasovými hodnotami jsou považovány za jasnější a jsou označeny bílou barvou, zatímco objekty s nižšími jasovými hodnotami jsou považovány za méně jasné a jsou označeny černou barvou. Tento práh může být nastaven manuálně nebo automaticky na základě histogramu obrázku.

Existuje také adaptivní prahování, kde se prahová hodnota může měnit v závislosti na vlastnostech okolních bodů. Tato metoda umožňuje lépe segmentovat objekty s různou intenzitou jasu v různých částech obrazu. Pro dosažení ještě lepších výsledků segmentace se může využít i dvojitého prahování, například pomocí Cannyho detektoru, nebo přidání Gaussovského šumu. Gaussovský šum dokáže výsledný obraz zpřesnit, jelikož prahování samo o sobě může být citlivé na šum [4],[6].

Prahování se také používá při segmentaci barevných obrazů, kde se pro každou barvu v obraze stanovuje vlastní práh. Tímto způsobem lze segmentovat objekty s různými barevnými vlastnostmi a rozlišovat různé složky obrazu na základě jejich jasových hodnot.



Obrázek 11 Příklad použití adaptivního prahování: Zdroj vlastní

3.2.3 Metoda rostoucích regionu

Jedná se o techniku pro extrakci oblastí obrazu. Tyto oblasti jsou spojeny na základě předem definovaných kritérií, jako jsou informace o intenzitě nebo okraje v obraze. Jednoduše řečeno, metoda potřebuje startovací bod, který je zvolen uživatelem. K tomuto bodu jsou následně shlukovány body obrazu se stejnou hodnotou intenzity.

Při použití této metody na RTG snímku kosti metoda následuje 3 kroky

Krok – Identifikace počátečního bodu v kostní struktuře

Krok – Výpočet spojitostí okolních bodů s počátečním bodem

Krok – Implementace vybraných kritérií pro podobnost bodů za účelem zastavení růstu

Výhoda této metody spočívá v tenkosti okrajů regionu a jejich dobré spojitosti. Algoritmus má stabilní výsledky, ale je náchylný na šum. Jako další výhodu lze považovat nastavení více kritérií pro členství bodů v regionu (např. nízký gradient, intenzita úrovně šedé) [9],[12],[14].

3.2.4 Shlukování

Tato metoda rozděluje body do několika skupin (shluku). Data jsou rozdělena a přiřazeny do daných skupin na základě jejich podobnosti. Cílem je získat několik skupin v kterých se nachází body s největší podobností. Samotnou metodu lze ještě rozdělit do dvou podskupin, a to na základě toho, jak jsou body do skupin přiřazovány. V první možnosti se jedná o tzv. „hard clustering“ kde je posuzováno, zda bod do skupiny patří úplně nebo vůbec. To znamená že nedochází k překrývání shluku, jelikož pro každou hodnotu připadá pouze jeden shluk. U druhé možnosti tzv. „soft clustering“ není bod přiřazen do dané skupiny, místo toho je určená pravděpodobnost toho, zda se data ve skupině bodu nacházejí. Tato pravděpodobnost je poté přiřazena posuzovanému bodu. Ve výsledku některé body ve shluku jsou přiřazeny do ostatních shluku [6],[12],[13],[14].

K jednomu z nejvyužívanějších algoritmu patří konvektivní modely, kde jsou tyto modely založeny na představě, že datové body blíže v datovém prostoru vykazují navzájem větší podobnost než datové body ležící dále. K datovým bodům přistupují modely dvěma způsoby. V prvním přístupu začínají klasifikací všech datových bodů do samostatných shluků a poté je agregují, se snižující se vzdáleností. Ve druhém přístupu jsou všechny datové body klasifikovány jako jeden shluk a poté rozděleny, v závislosti na zvětšující se vzdálenosti. Tyto modely jsou velmi snadno interpretovatelné, ale postrádají škálovatelnost pro práci s velkými datovými sadami.

Dalším nejpoužívanějším algoritmem jsou modely těžiště. Jedná se o iterativní shlukovací algoritmy, ve kterých je míra podobnosti odvozena z blízkosti datového bodu k těžišti shluků. Patří zde například metoda k-means (viz. kapitola 3.3.4).


Můžeme se také setkat s algoritmy jménem distribuční modely a modely hustoty. U distribučních modelů jsou shlukování založeny na představě, jak pravděpodobné je, že všechny datové body v shluku patří do stejné oblasti. Modely hustoty vyhledávají v datovém prostoru oblasti s různou hustotou datových bodů. Izoluje různé oblasti s různou hustotou a přiřazuje datové body v rámci těchto oblastí ve stejném shluku [22].

3.2.5 Shlukování metodou k-středů (k-means)

Shlukování metodou k-středů je jedna z nejmodernějších metod. Tento algoritmus třídí data do shluku na základě jejich vlastnosti. Na začátku algoritmu se určí počet shluku k. Tento počet shluku je menší než počet objektů v obrazu. Algoritmus poté přiřazuje body do shluku k nejbližšímu těžišti. Tyto těžiště se při každém spuštění tohoto algoritmu spočítají jako aritmetické průměry všech bodů shluku. Cílem je dosáhnout co nejmenšího rozdílu mezi body uvnitř shluku [6],[14],[21].

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} (\|x_j - \mu_i\|)^2 \quad (4)$$

Kde V je množina středů, k je počet shluků S_i , i je od 1 po k a μ_i je střed shluku.




Obrázek 12 Příklad použití K-means segmentace na RTG snímku fraktury, na pravé straně obrázku lze vidět výstup K-means segmentace, každá barva představuje jeden shluk pixelu s podobnou jasovou intenzitou: Zdroj vlastní

3.2.6 Metoda rozdělení a spojení obrazu (Split and Merge)

Je to jedna z nejjednodušších metod pro segmentaci obrazu. Jako vstup je zapotřebí definovat úroveň prahu. Obrázek je následně rozdělen na menší regiony nebo spojen do jednoho na základě tohoto definovaného předem definovaného vstupu. Rozdělení regionu se opakuje do doby, kdy už region nelze dále rozdělit. Pokud jsou tyto rozdělené regiony podobné dochází k jejich spojení, tento proces se stejně jako u rozdělení opakuje do doby, kdy už žádná spojení nejsou možná [20].

3.2.7 Watersheds(přehrad)

Segmentace pomocí přehrad je konceptuálně chápána jako simulace záplavy, kde vstupní šedotónový obrázek je považován za topografický povrch. Cílem je identifikovat „povodňové linie“ na tomto povrchu. Pro identifikaci povodňové linie jsou vytvořeny díry na každém regionálním minimu v obrázku. Poté je topografie postupně zatápěna shora dolů, umožňující vodě stoupat rovnoměrně po celém obrázku, začínaje u každého regionálního minima. Když se voda z různých minim blíží k sobě, jsou budovány hráze, aby se zabránilo jejich sloučení. Nakonec dosáhne záplava fáze, kdy jsou viditelné pouze vrcholy hrází nad hladinou vody, což odpovídá „povodňovým liniím“. Výsledné oblasti vytvořené různými regionálními minimy se nazývají „povodňové pánve“. Tato metoda je vcelku rychlá a intuitivní a lze s ní rozsegmentovat i obraz s nízkou úrovní kontrastu bez nutnosti jej před segmentací upravovat. Mezi nevýhody patří riziko nadbytečné segmentace obrazu [6],[12],[14],[31].



Obrázek 13 Princip segmentace pomocí přehrad [31]

a) vstupní obraz (64x64); b) morfologický gradient; c) segmentace Watersheds na morfologickém gradientu; d) segmentace Watersheds na morfologickém gradientu s odfiltrovanými minimy [31]


3.2.8 Metody založené na detekci hran

Detekce bodů a hran se soustředí na identifikaci konkrétních bodů nebo hran v obraze, které mají významnou informaci pro segmentaci. Tyto metody využívají například změny intenzity, gradientu nebo textury v obraze k identifikaci bodů nebo hran, které mohou reprezentovat objekty či jejich části. Metody detekce bodů a hran jsou často používány pro segmentaci objektů s výraznými hranami, jako jsou například objekty na snímcích CT nebo MRI v medicínském zpracování obrazu. [4]

3.2.8.1 Detekce bodů a hran

Tyto detektory jsou založeny na detekci gradientu v obraze, jinak řečeno detekují místa, kde dochází k náhlým změnám jasů. Tyto hranové detektory můžeme rozdělit do 3 skupin [4]:

- Trasformace (Fourierova, Laplaceova)
- Operátory (Robertsův, Sobelův, Kirschův)
- Cannyho detektor, detektor Marra-Hildreth



Obrázek 14 Příklad použití Cannyho detektorů hran, pravá strana obsahuje výstup Cannyho detektoru po aplikaci v oblasti fraktury: Zdroj vlastní

3.2.8.2 Segmentace na základě derivace obrazové funkce

Všechny tyto algoritmy sdílí jednu vlastnost, a to využití první nebo druhé derivace k nalezení extrémů. Musí platit několik základních principů pro numerickou derivaci, kdy je určena aproximace derivace funkce intenzity v daném bodě [4].

Aproximace první i druhé derivace musí být nulová v místech s konstantní intenzitou
Aproximace první i druhé derivace musí být nenulová tam, kde se hodnota intenzity mění
Aproximace první derivace musí být nenulová v bodech v těsné blízkosti změn intenzity, avšak pro druhou derivaci musí být v těchto bodech nulová

V případě, kdy se jedná o obraz diskrétní místo derivací pracujeme s diferencemi. Pokud se jedná o jednorozměrnou funkci $f(x)$ lze vyjádřit pomocí vzorce [4]:

$$\frac{\partial f}{\partial x} = f(x + 1) - f(x) \quad (5)$$

$\frac{\partial f}{\partial x}$ popisuje změnu úrovně jasu ve směru osy x , z důvodu dvojrozměrnosti funkce budou počítány parciální derivace ve směru dvou os. Pro obrazový bod (x, y) tedy platí následující diferenční vzorce [4]:

$$\frac{\partial f(x, y)}{\partial x} = f(x + 1, y) - f(x, y) \quad (6)$$

$$\frac{\partial f(x, y)}{\partial x} = f(x + 1, y) - f(x, y) \quad (7)$$

Člen $\frac{\partial f(x, y)}{\partial x}$ popisuje změnu úrovně jasu ve směru osy x ; $\frac{\partial f(x, y)}{\partial x}$ představuje změnu úrovně jasu ve směru osy y .

Pro druhou derivaci platí [4]:

$$\frac{\partial f^2(x, y)}{\partial x^2} = f(x + 1, y) + f(x + 1, y) \quad (8)$$

$$\frac{\partial f^2(x, y)}{\partial x^2} = f(x, y - 1) - 2f(x, y) + f(x, y + 1) \quad (9)$$

3.2.8.3 Detekce hranových bodů

K detekci hranového bodu lze použít Laplacián. Při této operaci je nutno stanovit diskrétní derivaci druhého řádu a následně v závislosti na ní vytvořit filtrační masku. Jako filtrační masky se používají izotropní filtry, které fungují nezávisle na rotaci obrazu. Pro obrazovou funkci $f(x, y)$ lze definovat Laplacián ∇^2 :

$$\nabla^2 f = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (10)$$

Přičemž $\frac{\partial^2 f(x, y)}{\partial x^2}$ a $\frac{\partial^2 f(x, y)}{\partial y^2}$ jsou diskrétní derivace druhého řádu a (x, y) jsou souřadnice obrazového bodu. Po aplikaci filtrační masky čtverce o velikosti např. 3x3 která nerotuje lze vypočítat konvoluce. Bez filtrační masky lze zjistit pouze velikost hrany.

3.3 Aktivní kontury

Existují dvě formy aktivních kontur. První je parametrická forma a druhá je implicitní forma. V parametrické formě, označované také jako hadi, se používá explicitní parametrická reprezentace křivky. Tato forma je nejen kompaktní, ale i účinná jak vůči obrazovému šumu, tak nedostatků v hranicích objektu, protože se tato forma snaží extrahované hranice, tak aby byly hladké. Kvalita segmentace závisí na dobře zvolených vstupních parametrech, při změně topologie nebo tvaru obrázku se musí tyto parametry znova definovat. To může být u některých obrázků časově náročné. Oproti tomu implicitní deformovatelné modely, nazývané také implicitní aktivní kontury nebo množiny úrovní, jsou navrženy tak, aby přirozeně zvládaly topologické změny.

Uživatel zadá počáteční odhad obrysu, který se pak přesune silami řízenými obrazem k hranicím požadovaných objektů. U takového modelu pracuje algoritmus s dvěma typy sil. Vnitřní síly definované v křivce jsou navrženy tak, aby udržely model hladký během procesu deformace, zatímco vnější síly, které jsou vypočítány z podkladových obrazových dat, jsou definovány tak, aby se pohybovaly směrem k hranici objektu nebo jiným požadovaným prvkům v obraze

Počáteční kontura může být umístěn uvnitř nebo vně objektu a v závislosti na tomto výběru se může pohybovat buď dovnitř nebo ven. Pokud je počáteční kontura vložena mimo objekt kontura segmentuje vnější stranu hrany objektu. Jestliže se v okraji objektu nachází díra, segmentace nebude přesná. To lze vyřešit umístěním počáteční kontury dovnitř objektu [23].

Snake model („Hadi“)

Tento segmentační model má schopnost vyřešit velké množství segmentačních problémů. Hlavní funkce tohoto modelu je identifikovat a obkreslit objekt určený k segmentaci. Je vyžadovaná už předem znát přibližný tvar cílového objektu. Tento model vychází ze vzorce


$$E_{snake} \int_0^1 E_{snake}(v(s)) ds = \int_0^1 (E_{internal}(v(s)) + E_{con}(v(s))) ds \quad (11)$$

Kde $E_{internal}$ je vnitřní elastický energetický člen a vnější energetický termín založený na hraně $E_{external}$. Účelem vnitřního energetického členu je regulovat deformace hada, zatímco funkcí

vnějšího energetického členu je řídit kontury zapadající do obrazu. Externí energie jsou typicky tvořeny kombinací sil způsobených obrázkem Eimage, a omezující síly uživatele Econ.

V oblasti lékařského zobrazování se hadí model používá k segmentaci jedné části obrazu, která má jedinečné vlastnosti ve srovnání s jinými oblastmi obrazu. Tradiční aplikace hadího modelu v lékařském zobrazování zahrnují segmentaci optického disku a pohárku k identifikaci glaukomu, segmentaci buněčného obrazu, segmentaci vaskulární oblasti a segmentaci několika dalších oblastí pro diagnostiku a studium poruch nebo anomálií [23].

Příklad použití aktivních kontur s 200 interakcemi na kosti pro detekci fraktury:



Obrázek 15 Příklad použití aktivních kontur: Zdroj vlastní

4 Tvorba datové báze RTG dat fraktur variabilních kostí.

Pro vstup do tohoto segmentačního modelu byly vytvořeny dva datasety. První dataset byl zaměřen na analýzu problematiky fraktur a obsahoval 16bitové snímky fraktur zápěstí. Tyto snímky měly nižší kvalitu, zejména nízký kontrast, což vyžadovalo zvýšenou pozornost při předzpracování dat. Celkem tento dataset obsahoval 20 304 snímků ve formátu DICOM. Jednou z výhod tohoto datasetu bylo, že ke každému snímku byl přiložen JSON soubor, který obsahoval informace o fraktuře s označenou oblastí, kde se fraktura nachází. Tímto způsobem bylo možné získat důležité informace o lokalizaci fraktury, které byly následně využity pro analýzu v segmentačním modelu.

Druhý dataset obsahoval záznamy 10 pacientů. Tyto záznamy obsahovaly dynamické snímky fraktur ve formátu 8 bitů. Tyto snímky měly vyšší kvalitu oproti prvnímu dataset, avšak neobsahovaly informace o lokalizaci fraktury. Fraktury v tomto datasetu byly také komplexnější, jednalo se například o fraktury článků prstů, ramen a klíčních kostí, což vyžadovalo odbornou analýzu a posouzení pro lokalizaci fraktury. Tento dataset byl využit pro analýzu dynamiky hojení

4.1 Dataset 1

Dataset 1 obsahuje 20 304 RTG snímku zápěstí. Jedná se o 16bitové RGB DICOM snímky. Oproti datasetu 2 obsahují informaci o fraktuře, zda se jedná o frakturu a pokud ano tak kde se ve snímku nachází. Rozlišená snímku v tomto datasetu se pohybovalo okolo 900x1200.



Obrázek 16 RTG snímky fraktur zápěstí z datasetu 1: Zdroj vlastní

4.2 Dataset 2

Dataset 2 obsahuje dynamické RTG snímky fraktur 10 pacientů. Jedná se o 8bitové RGB PNG snímky. Tento dataset neobsahuje informace o fraktuře, takže bylo zapotřebí identifikovat kde se v snímku fraktura nachází.

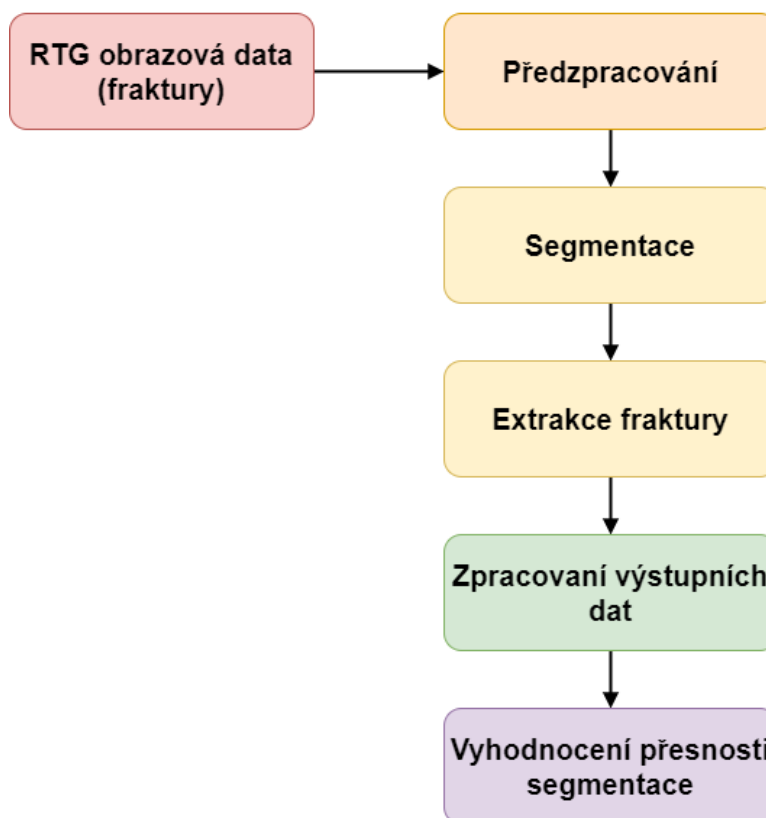


Obrázek 17 Variabilní snímky kostí z datasetu 2: Zdroj vlastní

5 Návrh a implementace segmentačního modelu pro identifikaci kostí z RTG obrazů.

Při návrhu segmentačního modelu byl algoritmus rozdělen na tři základní části, a to na předzpracování, segmentaci a automatickou extrakci fraktury. U předzpracování aplikujeme na RTG snímky několik postupů. Hlavním cílem předzpracování RTG obrazu je transformovat surová data obrazu na čistá data, eliminováním problémů jako je šum, chybějící nebo neúplné hodnoty, nesrovnalosti a chybné hodnoty.

Účelem předzpracování obrazu je zlepšit kvalitu dat obrazu snížením nespolehlivých zkreslení nebo zlepšením klíčových vlastností obrazu, které jsou důležité pro další zpracování. V případě dvou vstupních datasetů bylo zapotřebí upravit jas za účelem zvýšení viditelnosti struktur v obraze v tomto případě viditelnost fraktury. Také bylo zapotřebí sjednotit bitovou hloubku obrazu. Pro tento algoritmus byla zvolena 8bitová hloubka (data v rozmezí od 0 do 256) pro následnou lepší práci s daty. Posledním krokem u předzpracování byla aplikace mediánového filtry, který nám odstranil nežádoucí šum. U segmentace byl cíl binarizovat obraz pomocí prahování následně provést binární morfologické operace na odstranění nežádoucích objektů v obraze. Posledním krokem v tomto bodu bylo použití aktivních kontur na vytvoření binární masky fraktury. Tato binární maska je použita pro následnou extrakci fraktury. Z extrahované fraktury je zapotřebí zpracovat data jako jsou jasové intenzity, medián a směrodatná odchylka. Finálním krokem bylo vyhodnotit přesnost segmentace na základě tzv. gold standardu což byla manuálně segmentovaná binární maska fraktury [30].



Obrázek 18 Diagram pro návrh segmentačního modelu: Zdroj vlastní


5.1 Předzpracování

Jak už bylo předem avizováno je potřeba sjednotit bitovou hloubku obrazových dat. Pro tento algoritmus byla zvolena bitová hloubka 8 bitů to znamená že se hodnoty v obraze pohybovaly od 0 do 256 (28). 8bitová hloubka byla zvolena pro lepší práci s daty, jelikož hodnoty v obraze dosahovali maxima 256 oproti 16bitovému rozhraní kde hodnoty dosahují maxima 65536 (216). Bitová hloubka nám také ovlivnila úpravu kontrastu, jelikož se hodnoty roztáhly na škálu hodnot, kterou obraz nabízí.

Následně bylo z každého RTG snímku extrahováno ROI, tedy oblast, ve které se nacházela fraktura. Pro následnou analýzu procesu hojení bylo nezbytné zajistit, aby ROI mělo stejnou velikost pro každý RTG snímek. Pro tento účel byl jako první krok vybrán střed fraktury pomocí kurzoru, který určil souřadnice X a Y. Poté byla definována velikost ROI s hodnotami X1 a Y1.

$$X_2 = X - \frac{X_1}{2} \quad Y_2 = Y - \frac{Y_2}{2} \quad (12)$$

Na základě bodů X1, Y1, X2 a Y2 byla extrahována požadovaná oblast snímku (Obrázek 19). Následně proběhl převod ROI z RGB formátu na stupně šedi.



Obrázek 19 Extrahované ROI: Zdroj vlastní

5.1.1 Lineární úprava kontrastu


Dalším krokem u předzpracování byla úprava kontrastu. Úprava kontrastu je proces, při kterém dochází ke změně rozdílu mezi nejjasnějšími a nejtemnějšími oblastmi na obrázku. Na snímky byla aplikovaná lineární úprava kontrastu

Při této úpravě kontrastu jsou jasové hodnoty pixelů rovnoměrně rozloženy na celou škálu pixelů, kterou snímek nabízí.

$$K = \frac{(I - \min_{\text{vstup}}) \times (\max_{\text{výstup}} - \min_{\text{výstup}})}{(\max_{\text{vstup}} - \min_{\text{vstup}}) + \min_{\text{výstup}}} \quad (13)$$


Kde I je vstupní obraz, \min_{vstup} a \max_{vstup} jsou dolní a horní hranice vstupního obrazu, $\min_{\text{výstup}}$ a $\max_{\text{výstup}}$ jsou dolní a horní hranice výstupního obrazu.

Cílem této úpravy bylo zlepšit viditelnost detailů. Na histogramu původního snímku (levá strana obrázku 20) lze vidět nepatrný jasový rozdíl mezi pixely. Po aplikaci lineární úpravy (pravá strana obrázku 20) se hodnoty jasu pixelů rovnoměrně rozprostřely po celém spektru jasů, který je k dispozici na snímku. Na histogramech lze vidět jasové rozložení pixelů I [-] a počet pixelů n [-].



Obrázek 20 Levá strana obrázku obsahuje histogram před lineární úpravou, pravá strana obsahuje histogram po úpravě


Při pohledu na horní část obrázku 21 lze vidět, jak je kost na snímku špatně viditelná, dalo by se říct, že některé oblasti kosti splývají s pozadím snímku. Takto neupravený snímek může způsobit řádu nechtěných segmentačních chyb například u segmentační metody prahování. Po úpravě snímku (dolní část obrázku 21) lze vidět mnohem lepší rozdíl mezi nejtemnější a nejjasnější oblastí snímku. Přejechod mezi pozadím a kostí je mnohem viditelnější.



Obrázek 21 Úprava kontrastu, horní část obsahuje obrázky před úpravou kontrastu, dolní část obsahuje obrázky po úpravě kontrastu: Zdroj vlastní

5.1.2 Mediánový filtr

Finálním krokem v přepracování bylo použití mediánového filtru. Pro odstranění šumu byl aplikován 2 D mediánový filtr o velikosti 3x3. Na horní části obrázku 22 lze vidět neupravené „zašumělé“ obrazová data. Na spodní straně obrázku 22 lze vidět výrazné potlačení šumu jak v oblasti kosti, tak na pozadí snímku. I přesto že se jedná o takto malý šum je ho zapotřebí eliminovat. Jakékoli množství šumu může způsobit nežádoucí komplikace při segmentaci obrazu. Je potřeba brát na vědomí že při použití příliš velkého filtračního jádra dochází k výraznému posunutí hrán v obraze.



Obrázek 22 Mediánový filtr 3x3, Horní část obrázku obsahuje RTG snímky před aplikací filtru, spodní část obsahuje data po aplikaci filtru: Zdroj vlastní

Mediánový filtr je nelineární filtr používaný k vyhlazování signálů. Je zvláště účinný při odstraňování impulsivního šumu ze signálu. Existuje několik variant tohoto filtru. V případě digitálního zpracování obrazu se často používá dvoudimenzionální verze k odstranění šumu a skvrn z obrazů.

Nelineární funkce mediánového filtru lze vyjádřit jako:

$$y(n) = \text{med} [x(n - k), x(n - k + 1), x(w), x(n + k - 1), x(n + k)] \quad (14)$$

kde $y(n)$ je výstup a $x(n)$ je vstupní signál. Filtr "shromažďuje" okno obsahující $N = 2k+1$ vzorků vstupního signálu a poté provádí mediánovou operaci na této sadě vzorků.

Mediánová operace zahrnuje seřazení vzorků podle velikosti a vybrání vzorku s prostřední hodnotou (mediánem). Z tohoto důvodu je N obvykle zvoleno jako liché číslo [30].

Pokud je nutné použít sudý počet vzorků v okně, medián je definován následovně, za předpokladu, že vzorky jsou seřazeny tak, že x , je nejmenší hodnota a $x(n+k)$ je největší hodnota [30].

$$med[x_1, x_2 \dots x_N] = \begin{cases} x_{k+1} & \text{pro } N = 2k + 1 \\ \frac{1}{2}(x_k + x_{k+1}) & \text{pro } N = 2k \end{cases} \quad (15)$$

Příklad funkce mediánového filtru s filtračním jádrem 3x3:

77	22	21	228	217	210
68	67	18	103	196	45
32	125	13	75	66	220
117	6	142	107	229	161
57	191	184	150	245	143
206	239	105	41	20	140
157	217	245	228	230	239

→

13
18
21
22
32
67
68
77
125

→

			228	217	210
	32		103	196	45
			75	66	220
117	6	142	107	229	161
57	191	184	150	245	143
206	239	105	41	20	140
157	217	245	228	230	239

5.2 Segmentace s cílem identifikace fraktury kostí


Cílem tohoto kroku je oddělit frakturu od zdravé kosti, pro tento krok je využito Adaptivního prahování a morfologických funkcí. U tohoto kroku je zapotřebí dbát na přesné a precizní ohraničení fraktury pro následné zpracování dat jako je například obvod a obsah fraktury pro analýzu dynamiku procesu hojení. Musíme dbát na fakt, že byl použit mediánový filtr, proto bylo využito aktivních kontur pro finální bod segmentace. Pro lepší výsledek segmentace byl snímek zbaven pozadí. Pomocí prahování byla vytvořena binární maska kosti. Následně byla maska vynásobena s originálním snímkem a tím byla zbavena pozadí. Stejně jako u bodu 5.1.1 byl na separované kosti upraven kontrast úprava kontrast, následně došlo k binarizaci snímku pomocí adaptivního prahování. Výsledný binární snímek obsahoval velký počet děr. Pro eliminaci těchto děr byla použita dilatace. Dilatace způsobila rozšíření hran fraktury, proto byla následně aplikovaná eroze. Výsledkem byl binární obrázek kde zdravá kost nesla logickou hodnotu 1 a fraktura logickou 0. Pro extrakci binární masky fraktury byla provedena binární inverze. Pro lepší ohraničení fraktury byly na snímek aplikovány aktivní kontury.

5.2.1 Morfologické operace

Na vyfiltrovaném obrázku byla provedena dilatace se strukturálním elementem tvaru disk s velikostí 4.


Tento strukturální element prochází po celém obrazu a v každém bodě se porovná s okolními body obrázku. Pokud se v okolí nachází alespoň jeden bod, který patří k objektu, pak se tento bod přiřadí k výslednému dilatovanému objektu [31].

Cílem této operace bylo zaplnění nežádoucích děr. Taktéž šlo o potlačení hranic fraktury, aby došlo k segmentaci celé kosti. Opět na horní straně obrázku 23 vidíme RTG data před aplikací dilatace.



Obrázek 23 Dilatace se strukturálním elementem tvaru disk velikosti 4, horní část obrázku obsahuje RTG snímky před aplikací dilatace, spodní část obrázku obsahuje výsledek dilatace: Zdroj vlastní

Po dilataci byla aplikovaná eroze se strukturálním elementem tvaru disk o velikosti 3. Stejně jako u dilatace, strukturální element je aplikována na celý obrázek a v každém bodě je porovnávána s okolními body. Pokud v okolí není přítomen celý soubor bodů uvedených ve strukturálním elementu, je daný bod odebrán z výsledného erozovaného objektu. Cílem této operace bylo oddělení objektů v obraze. Na spodní straně obrázku 24 lze vidět mnohem přesnější ohraničení hran kosti.



Obrázek 24 Eroze se strukturálním elementem tvaru disk velikost 3, horní část obrázku obsahuje obrázek před erozí, dolní část obrázku obsahuje RTG snímky po erozi: Zdroj vlastní

Výsledkem tohoto zpracování je tedy mnohem přesnější ohraničení hran kosti, což je vidět na spodní straně obrázku 24. Díky použití dilatace, byly objekty v obraze správně odděleny a jejich hranice byly přesněji definovány. Pro vytvoření binární masky bylo použito Adaptivní prahování.

5.2.2 Adaptivní prahování

Adaptivní prahování je metoda zpracování obrazu, která umožňuje určit práh pro segmentaci obrazu na základě lokálního okolí nebo regionu, namísto použití jednotného globálního prahu pro celý obraz. To znamená, že práh je určen nejen pro každý obraz samostatně, ale také pro každou oblast uvnitř obrazu zvlášť. To je užitečné v situacích, kdy jednoduchý předpoklad objektu a pozadí není globálně platný kvůli nepřerušným gradientům jasu, jako například při nepravidelném osvětlení nebo změnách kontrastu v obrazu. Adaptivní prahování umožňuje lépe přizpůsobit práh místním podmínkám v obrazu, a tak dosáhnout přesnější segmentace objektů z pozadí. Existuje několik různých metod adaptivního prahování, včetně pixel-adaptivního prahování, kde je práh určen pro každý pixel zvlášť na základě jeho vlastního okolí, což umožňuje ještě vyšší úroveň přizpůsobení práhu lokálním podmínkám v obraze [31].



Obrázek 25 Prahování otsu metodou na základě histogramu obrázku: Zdroj vlastní

Pro vytvoření binární masky kosti byla použita Otsu metoda, která vybírá hodnotu prahu tak, aby minimalizovala vnitřní třídní rozptyl binarizovaných černobílých pixelů. Metoda využívá 256bitový histogram obrazu k výpočtu hodnoty prahu [41].


5.2.3 Separace kosti od pozadí

Na základě této binární masky byl snímek zbaven pozadí kde se kost s frakturou nenacházela. Binární maska byla vynásobená originálním vstupním snímkem. Vynásobením binární masky s originálním obrázkem získáme pouze oblast kosti. Tuto operaci můžeme vidět na příkladu kde první část tabulky 1 představuje binární masku a druhá část tabulky 1 obrázek. Třetí část tabulky je výstup této operace.

Tabulka 1 Extrakce objektů z obrazu na základě binární masky

0	0	0	0	X	235	211	172	138	→	0	0	0	0
0	0	1	0		211	98	13	166		0	0	13	0
0	1	1	1		201	23	20	28		0	23	20	28
0	1	1	0		208	41	12	182		0	41	12	0
0	0	0	0		103	115	103	158		0	0	0	0

Obrázek 26 obsahuje výstup 9 separovaných kostí, tyto kosti byly odděleny od pozadí na základě binárních masek z obrázku 29



Obrázek 26 Separovaná kost: Zdroj vlastní

5.2.4 Úprava kontrastu separované kosti

Na snímek byla opět aplikovaná úprava kontrastu (bod 5.1.1, jelikož se u separace od pozadí vycházelo z originálního obrázku). Na levé straně obrázku 27 lze vidět separované kosti před úpravou kontrastu.


Pravá strana obrázku 27 obsahuje úpravné kosti. Lze vidět výraznou změnu ve viditelnosti struktur které se v kosti nachází.



Obrázek 27 Úprava kontrastu, Levá strana obrázku obsahuje 9 neupravených kostí, pravá strana obrázku obsahuje kosti po úpravě: Zdroj vlastní

5.2.5 Adaptivní prahování separované kosti

Za využití lokálního adaptivního prahování s citlivostí 0.62 byla vytvořena binární maska (levá strana obrázku 28). Na levé straně obrázku 32 lze pozorovat velké množství děr. Z tohoto důvodu byly binární masky uzavřeny. Jako první byl vytvořen strukturální element tvaru disk velikosti 4. Následně byl tento element využit pro dilataci a erozi. Výstupem byly eliminovány všechny díry v masce menší než 4 (bod 5.2.7).



Obrázek 28 Adaptivní prahování + Dilatace, Levá strana obsahuje výstup adaptivního prahování s citlivostí 0.62, Pravá strana obsahuje výstup dilatace: Zdroj vlastní

5.2.6 Aktivní kontury (hranové)

Na binární masku byly aplikovány aktivní kontury, které vycházely z hran. Metoda detekce hran (edge) využívá hranové informace na obrazu k výpočtu energie aktivních kontur. Tento přístup je založen na předpokladu, že objekt na obrazu má výrazné hrany nebo okraje, a že tyto hrany lze využít k přesnému určení tvaru objektu. Metoda detekce hran může být v některých případech citlivá na šum v obrazu nebo na překážky v cestě aktivních kontur. [42][23]


Výsledkem byly binární masky kde fraktura nesla logickou hodnotu 0. Výsledkem byly mnohem kvalitněji segmentované fraktury (levá strana obrázku 29). Následně byla provedena binární inverze (pravá strana obrázku 29).



Obrázek 29 Aktivní kontury s 10 iteracemi+binární inverze, levá strana obsahuje aktivní kontury, pravá strana obsahuje binární inverzi: Zdroj vlastní

5.2.7 Binární morfologické operace

Pro co nejlepší segmentační výsledek byla na binární masky opět použita dilatace s erozí. V tomto případě se jednalo o erozi se strukturálním elementem velikosti 4 (levá strana obrázku 30). U dilatace byl použit strukturální element velikosti 3 (pravá strana obrázku 30).



Obrázek 30 Eroze se strukturálním elementem tvaru disk o velikosti 4, pravá strana obrázku obsahuje dilataci se strukturálním elementem o velikosti 3: Zdroj vlastní

Binární morfologické operace jsou obrazové operace, které se provádějí na binárních obrazových datech, kde každý pixel je přiřazen buď hodnotě TRUE (reprezentující objekty v obraze) nebo FALSE (reprezentující pozadí). Tyto operace se používají pro úpravu tvaru, velikosti, nebo struktury objektů v binárním obraze [31].


Morfologické operace se provádějí za použití předem definovaného strukturálního elementu (obvykle tvaru kruh, kříž nebo obdélník), který je aplikován na vstupní obraz pomocí logických operací, jako je dilatace (rozšíření) a eroze (zúžení). Dilatace objekty zvětšuje nebo zaokrouhluje, zatímco eroze je proces zmenšování nebo vyhlazování objektů. Kombinace těchto operací může být použita pro odstraňování šumů, zaplňování děr, oddělování objektů nebo spojování blízkých objektů [31].

5.2.8 Aktivní kontury (Chan-Vese)

V posledním kroku segmentace byly použity aktivní kontury „Chan-Vese“.

Metoda Chan-Vese využívá informace o rozdílech jasu vnitřních a vnějších oblastí objektu k výpočtu energie aktivních kontur. Tento přístup umožňuje segmentovat objekty, které nemají výrazné hrany nebo okraje, a může být robustnější vůči šumu a překážkám [37].


Masky z obrázku 30 byly použity jako počáteční bod pro aktivní kontury. Aktivní kontury poté začaly binární masku deformovat na základě energii v originálním obrázku. Pro aktivní kontury byl definován maximální počet interací na 200, což znamená že když aktivní kontury dosáhnou maximálního počtu iterací zastaví se evoluce. Následně byla tato výsledná maska použita pro separaci fraktury od kosti.




Obrázek 31 Aktivní kontury „Chan-Vese“, na levé straně se nachází binární masky před aplikací aktivních kontur, na pravé straně se nachází binární masky po aplikaci aktivních kontur: Zdroj vlastní

5.2.9 Separace fraktury

Pro srovnání jasových intenzit fraktury a zdravé kosti bylo nutné oddělit tyto objekty ze snímku. K tomu byla použita segmentovaná binární maska, která byla vynásobena se separovaným obrázkem kosti pro eliminaci nežádoucích objektů ve výsledném obraze. Tím bylo zajištěno, že se zachovaly pouze hodnoty odpovídající oblastem s hodnotou 1 v masce. Pro oddělení zdravé kosti bez fraktury byl použit stejný postup, avšak s jedním rozdílem – na segmentovanou masku byla aplikována binární inverze.



Obrázek 32 Princip separace fraktury, na levé straně snímku se nachází binární maska fraktury, uprostřed lze vidět původní obrázek, na pravé straně se nachází výstup separace



Obrázek 33 Na levé straně obrázku lze vidět separované fraktury. Pravá strana obsahuje separované kosti bez fraktur.

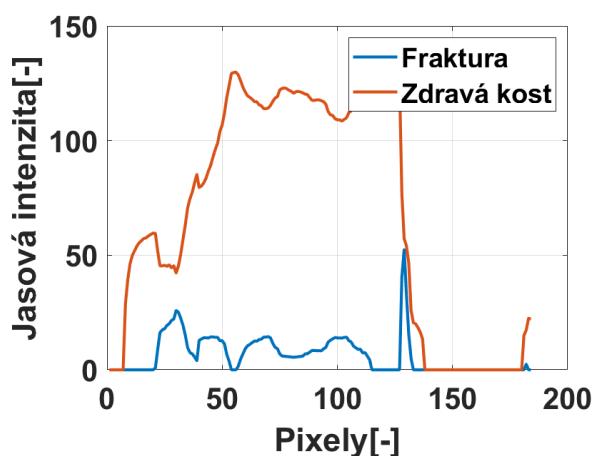
5.2.10 Výstupní data

K následné analýze fraktury je zapotřebí separované fraktury zpracovat. V tomto případě se jednalo o vypočet směrodatné odchylky, průměrných jasových intenzit a mediánu fraktury. Tyto data byly vypočítány ze snímku separované fraktury a separované zdravé kosti.


U dynamických snímku fraktur bylo zapotřebí také spočítat obvod a obsah fraktury pro analýzu dynamiky hojení.

Pro obvod na základě vzdálenosti mezi každým párem sousedních pixelů kolem okraje segmentované oblasti vypočítáme skalární hodnotu, která reprezentuje vzdálenost kolem hranice oblasti. U obsahu je to počet pixelu, který se v oblasti nachází.


Tyto informace nám umožňují sledovat dynamiku hojení fraktury, přičemž můžeme porovnávat změny obvodu a obsahu fraktury v průběhu času a vyhodnocovat tak úspěšnost hojení.



Graf 2 Porovnání jasové intenzity mezi frakturou a zdravou kostí: Zdroj vlastní



Graf 1 Porovnání jasové intenzity mezi frakturou a zdravou kostí: Zdroj vlastní



Obrázek 34 Výstup segmentačního modelu v MATLAB rozhraní

Na obrázku 34 lze vidět výstup segmentačního algoritmu v MATLAB rozhraní. Levá strana obrázku 34 obsahuje originální obrázek, následně je zobrazen výsledek adaptivního prahování, poté je zobrazen finální výsledek segmentace. Poslední část obrázku obsahuje vyznačenou frakturu, kde byl použit na binární masku cannyho detektor hran a následně tyto hrany byly vyznačeny na originálním obrázku.

6 Analýza výsledku segmentačního modelu

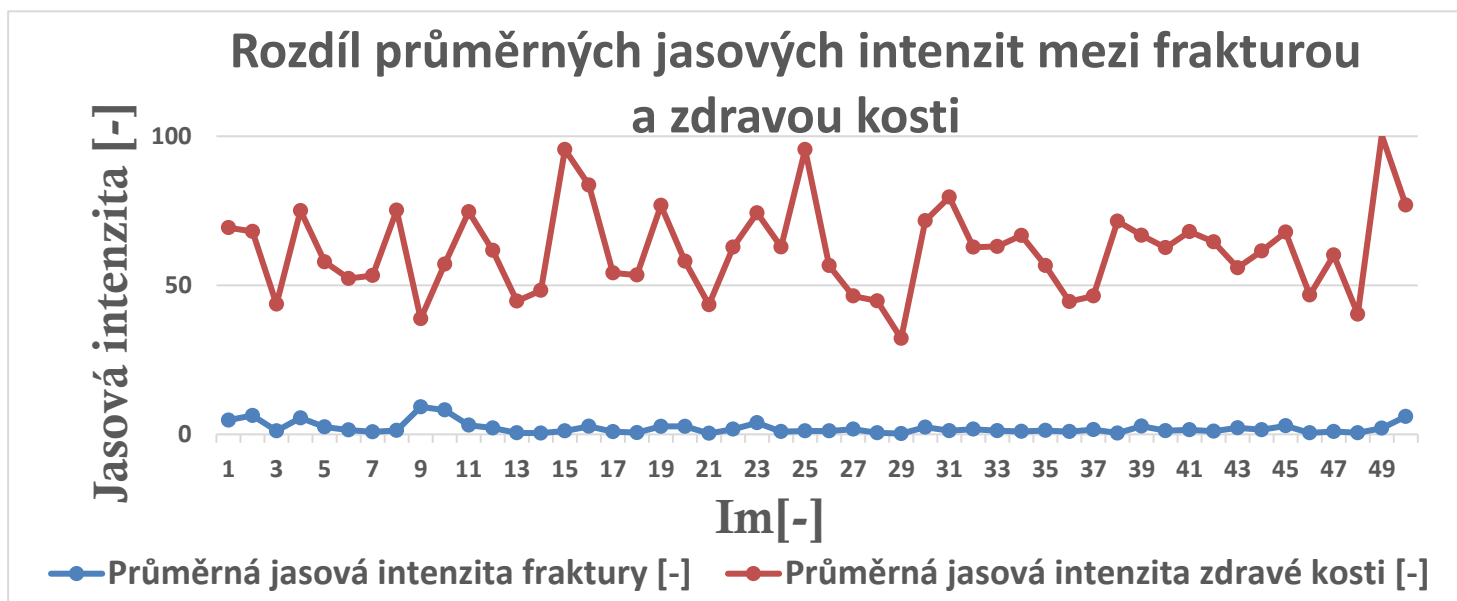
Tato kapitola je zaměřena na zpracování výsledku pro následnou analýzu procesu hojení. Pro tuto analýzu bylo zapotřebí extrahovat jasové intenzity jednotlivých fraktur, následně tyto data porovnat s daty zdravé kosti a vyhodnotit o kolik se jasová intenzita liší. Pro sledování dynamiky procesu hojení bylo taky zapotřebí analyzovat geometrickou změnu fraktur. Z tohoto důvodu bylo vypočítán obsah a obvod fraktury. V posledním bodu kapitoly byla vyhodnocena přesnost segmentace.

6.1 Jasové intenzity

Pro jasovou intenzitu byla z extrahovaných snímků fraktur spočítána průměrná jasová intenzita. Stejně tak pro zdravou kost.

Tabulka 2 Jasové intenzity fraktury a zdravé kosti

Průměrná jasová intenzita fraktury	Průměrná jasová intenzita zdravé kosti
1,8825	61,9883



Graf 3 Rozdíl průměrných jasových intenzit mezi frakturou a zdravou kosti

6.2 Směrodatná odchylka a medián

Pro každou frakturu byla také vypočítána směrodatná odchylka a medián

Tabulka 3 Směrodatná odchylka a medián fraktury

Průměrný medián fraktury	Průměrná směrodatná odchylka
1,8825	12,1879

6.3 Obvod a obsah fraktury

Jak už bylo zmíněno pro analýzu dynamiky procesu hojení bylo zapotřebí vypočítat obvod a obsah fraktury. Pro obvod na základě vzdálenosti mezi každým párem sousedních pixelů kolem okraje segmentované oblasti vypočítáme skalární hodnotu, která reprezentuje vzdálenost kolem hranice oblasti. U obsahu je to počet pixelu, který se v oblasti nachází. V tabulce 4 a 5 se nachází informace o rozměrech fraktury. Tabulka 4 obsahuje informace o obvodu fraktur tří pacientů. Tabulka 5 obsahuje výsledný obsah fraktur.

Tabulka 4 Obvod fraktury

Obvod	Pacient 1	Pacient 2	Pacient 3
Počátek fraktury	98,343	490,84	219,096
Konečný stav fraktury	5,905	163,644	52,8471

Tabulka 5 Obsah fraktury

Obsah	Pacient 1	Pacient 2	Pacient 3
Počátek fraktury	129	2426	570
Konečný stav fraktury	44	342	52,847

6.4 Vyhodnocení přesnosti segmentace

Pro vyhodnocení přesnosti segmentace bylo zapotřebí definovat takzvaný „zlatý standard“. V tomto případě se jednalo o manuálně segmentovanou frakturu.

Přesnost segmentace byla vyjádřena pomocí Dice koeficientu (též známého jako Sørensen–Dice koeficient)[43].


$$Dice = \frac{(2 \times TP)}{(2 \times TP + FP + FN)} \quad (16)$$

Kde TP (true positive) znamená počet pixelů, které jsou správně klasifikovány jako pozitivní v obou maskách, FP (false positive) znamená počet pixelů, které jsou nesprávně klasifikovány jako pozitivní v automaticky segmentované masce, ale jsou správně klasifikovány jako negativní v manuálně segmentované masce a FN (false negative) znamená počet pixelů, které jsou nesprávně klasifikovány jako negativní v automaticky segmentované masce, ale jsou správně klasifikovány jako pozitivní v manuálně segmentované masce [43].

Výsledkem Dice koeficientu je hodnota mezi 0 a 1, kde 1 znamená dokonalou shodu mezi oběma maskami a 0 znamená naprostou neshodu.

Tento segmentační model dosáhl průměrné přesnosti 0,8861. Je třeba brát v úvahu, že manuální segmentace nebyla provedena odborníkem, takže je možné, že některé manuálně segmentované fraktury nemusí odpovídat ideální segmentaci.

Tento krok byl časově nejnáročnější. Bylo zapotřebí přesně definovat oblast fraktury pro každý snímek v datasetu.




Obrázek 35 Porovnaná dvou binárních masek, levá část obrázku představuje manuální segmentaci, prostřední část obrázku obsahuje automatickou segmentaci, pravá část představuje fúzování segmentace s manuální maskou: Zdroj vlastní

Na obrázku 35 lze vidět matice devíti obrázku kde první řada která se nachází na levé straně představuje manuálně segmentovanou masku. Druhá řada obsahuje automaticky segmentovanou masku. Výsledek podobnosti lze vidět v třetí řadě. Třetí řada obsahuje fúzování segmentace se zlatým standardem. Fialová barva představuje plochu binární masky automatické segmentace. Zelená barva vyznačuje plochu binární masky manuální segmentace. Plochu, kterou tyto masky sdílí nese barvu bílou.

Na grafu 2 lze vidět přesnost segmentace pro jednotlivé fraktury. Im [-] představuje jednotlivé fraktury. Acc [-] je míra přesnosti segmentace, což znamená její podobnost s manuálně segmentovanou

maskou. Nejlepším možný výsledek představuje 1 kdy se binární masky podobají 1:1. Automaticky segmentovaná maska dosahovala průměrné podobnosti 0,8861. Nejhorší segmentovaný výsledek dosáhl podobnosti 0,4325. Nejlepší dosáhl hodnoty 0,995.



Graf 4 Přesnost segmentace fraktury


7 Analýza dynamiky procesu hojení kostí na základě navrženého modelu.

Pro analýzu dynamiky procesu hojení byl velký důraz kladen na velikost fraktury a její jasovou intenzitu. Z výsledků v tabulkách 6-8 lze pozorovat, že jasová intenzita se s časem zvyšuje, zatímco velikost zlomeniny se postupně snižuje. Nárůst jasové intenzity je zapříčiněn tvorbou takzvaného kalusu. Jedná se o vazovitou hmotu, která se tvoří v oblasti zlomeniny v rané fázi zlomeniny. Tato hmota se poté mění v kostní tkáň, což vede ke zvýšení hustoty a také větší absorpci RTG záření v oblasti fraktury.

Na obrázcích 36-38 lze vidět binární masky jednotlivých fraktur, kde levá strana obrázku obsahuje počátek stav fraktury a pravá konečný stav fraktury.

Tabulka 6 Pacient 1 fraktura v oblasti chodidla

Pacient 1	Průměrná jasová hodnota	Směrodatná odchylka	Obvod	Obsah
T1	0,2134	6,7403	98,343	129
T2	0,2239	5,6043	47,148	64
T3	0,4393	4,8741	5,905	44



Obrázek 36 Pacient 1, fraktura v oblasti chodidla, jedná se o fraktury s rozstupem přibližně dvou týdnů: Zdroj vlastní

Tabulka 7 Pacient 2, fraktura v oblasti ramene


Pacient 2	Průměrná jasová hodnota	Směrodatná odchylka	Obvod	Obsah
T1	1,0348	23,373	490,84	2426
T2	6,4032	27,8317	336,874	1531
T3	6,8603	9,7061	163,644	342



Obrázek 37 Pacient 2, fraktura v oblasti ramene, jedná se o fraktury s rozstupem přibližně 1 měsíce: Zdroj vlastní

Tabulka 8 Pacient 3, fraktura v oblasti paže

Pacient 3	Průměrná jasová hodnota	Směrodatná odchylka	Obvod	Obsah
T1	0,2223	7,5664	219,096	570
T2	0,8569	17,0927	211,892	386
T3	2,3613	5,6453	52,8471	52,847



Obrázek 38 Pacient 3, fraktura v oblasti paže, jedná se o fraktury s rozstupem přibližně 2 měsíců: Zdroj vlastní

8 Vyhodnocení výsledků práce

Z výsledné tabulky 9 lze vyčíst průměrnou jasovou intenzitu fraktury která se pohybovala okolo 1,8825.

Dále je z tabulky patrné, že průměrná jasová intenzita zdravé kosti byla o 60,1058 vyšší než u fraktury. Tato hodnota ukazuje rozdíl mezi jasovou intenzitou zdravé kosti a fraktury a naznačuje, že zdravá kost měla vyšší jasovou intenzitu než fraktura. Tento rozdíl je důležitým aspektem, který může být použit k hodnocení závažnosti fraktury a posouzení integrity kosti.

Tabulka 9 Výsledná tabulka pro dataset 2 (50 snímků)

Průměrná jasová intenzita fraktury	Průměrná jasová intenzita zdravé kosti	Průměrný medián fraktury	Průměrná směrodatná odchylka
1,8825	61,9883	1,8825	12,1879

Na základě prezentovaných výsledků lze říct, že jasová intenzita je klíčovým faktorem pro posouzení závažnosti fraktury a procesu hojení. Získané informace o průměrné jasové intenzitě zdravé kosti a fraktury ukazují rozdíl mezi oběma stavy kosti. V průběhu procesu hojení se jasová intenzita zvyšuje a velikost zlomeniny postupně snižuje, což je zapříčiněno tvorbou kalusu. Analýza segmentace fraktur ukázala, že navržený segmentační model dosáhl průměrné přesnosti 0,8861, což znamená, že automatická segmentace má vysokou míru podobnosti s manuální segmentací.

Zvolené segmentační metody pro tento typ analýzy byly dostačující, jelikož už z teoretické části bylo známo že fraktury se v obraze projevují jako velmi nízká úroveň jasu. Problém nastal v moment, kdy se v blízkosti fraktury nacházela sousední kost nebo úlomky poraněné kosti. V tento moment došlo k zvýšené absorpci RTG záření v oblasti fraktury což zapříčinilo zvýšenou jasovou hodnotu v obraze. Z tohoto důvodu se oblast fraktury nepohybovala v očekávaných hodnotách tudíž algoritmus nedokázal přesně určit kde se fraktura nachází. Na druhou stranu tento segmentační model dokázal pracovat i s velmi špatným kontrastem. Díky několika úpravám kontrastu a separaci pozadí dokázal rozlišit i okem špatně viditelné fraktury.

9 Závěr

Cílem této práce bylo vytvořit segmentační model pro analýzu procesu hojení. Pro tuto analýzu bylo zapotřebí vytvořit 2 datasey RTG obrazových dat. První dataset obsahoval RTG snímky fraktur zápěstí. Druhý dataset obsahoval dynamické snímky fraktur ramen, rukou a chodidel. Následně bylo zapotřebí snímky předzpracovat. Jako první byly všechny snímky převedeny do šedého rozhraní, což znamenalo převod z trojrozměrné matice na jednorozměrnou. Pro sjednocení výsledku bylo zapotřebí sjednotit bitovou hloubku. Dataset 1 obsahoval snímky s bitovou hloubkou 16bitu. Dataset 2 obsahoval snímky s bitovou hloubkou 8bitů. Pro lepší práci s daty byla zvolena bitová hloubka 8 bitů kde hodnoty dosahovali maxima 256. Snímky obsahovali nežádoucí množství šumu a velice špatný kontrast, z tohoto důvodu byla aplikovaná lineární úprava kontrastu společně s mediánovým filtrem. Výsledkem předzpracování byl mnohem lépe vypadající RTG snímek s potlačeným šumem a lepší viditelností objektů které se na kosti nachází.

Pro následnou analýzu procesu hojení bylo zapotřebí rozdělit kost na 2 části, a to na frakturu a zdravou kost. K tomuto rozdělení bylo využito adaptivního prahování a aktivních kontur. V prvním kroku bylo na snímek aplikováno adaptivní prahování s citlivostí od 0,50 do 0,70. Po aplikaci adaptivního prahování obsahovala binární maska spoustu nežádoucích objektů, které se nacházely v okolí fraktury. Pro eliminaci těchto objektů bylo využito binárních morfologických operací. Segmentovaná binární maska stále nedosahovala požadovaných výsledku pro přesné oddělení fraktury. Z toho důvodu byla samotná kost zbavena pozadí, to zapříčinilo odstranění nežádoucích objektů jako byla lidská tkáň. Tento krok výrazně zlepšil výstup adaptivního prahování, s kombinací morfologických funkcí a aktivních kontur byla výsledkem binární maska fraktury. Pro extrakci fraktury z originálního snímku byla binární maska vynásobená se snímkem separované kosti kde se nenacházelo pozadí.

Ze separovaného snímku fraktury byla vypočítaná průměrná jasová hodnota, medián a směrodatná odchylka. Jasová hodnota fraktury se pochybovala okolo 1,8825 oproti průměrné jasové intenzitě zdravé kosti, která byla o 60,1058 vyšší než u fraktury. Směrodatná odchylka se pohybovala okolo hodnoty 12,1879. Pro analýzu procesu hojení byl spočítán obvod a obsah fraktury. Na základě těchto parametrů bylo zjištěno že v průběhu procesu hojení se jasová intenzita zvyšuje a velikost fraktury postupně snižuje, což je zapříčiněno tvorbou kalusu. Tudíž se dá předpokládat, že při správném procesu hojení by měla jasová intenzita stoupat až k hodnotám zdravé kosti.

Pro vyhodnocení přesnosti segmentačního modelu byly vytvořeny manuálně segmentované masky fraktur. Tato manuálně segmentovaná maska byla porovnávána s automaticky segmentovanou maskou na základě Sørensen–Dice koeficientu. Výsledkem tohoto koeficientu bylo číslo od 0 do 1 kde 1 byl nejlepší možný výsledek (masky byly podobné 1:1). Přesnost tohoto segmentačního modelu dosahovala průměrné přesnosti 0,8861. Nejhorší segmentovaná maska měla přesnost 0,4325. Nejlepší segmentovaná maska měla přesnost 0,9956. I když analýza přesnosti segmentace fraktur ukázala, že navržený segmentační model dosahuje vysoké přesnosti segmentace nese tento model jednu nevýhodu. Jelikož tento segmentační model pracuje s jasovými intenzitami,

problém nastal v moment, kdy se v blízkosti fraktury nacházela sousední kost nebo úlomky poraněné kosti. V tento moment došlo ke zvýšené absorpci RTG záření v oblasti fraktury což zapříčinilo zvýšenou jasovou hodnotu v obraze. Z tohoto důvodu se oblast fraktury nepohybovala v očekávaných hodnotách tudíž algoritmus nedokázal přesně určit kde se fraktura nachází. Na druhou stranu tento segmentační model dokázal pracovat i s velmi špatným kontrastem. Díky několika úpravám kontrastu a separaci pozadí dokázal rozlišit i okem špatně viditelné fraktury.

Použitá literatura

- [1] NAVRÁTIL, Leoš a Jozef ROSINA. Medicínská biofyzika. 2., zcela přepracované a doplněné vydání. Praha: Grada Publishing, 2019. ISBN 978-80-271-0209-9.
- [2] MAHESH, Mahadevappa. The Essential Physics of Medical Imaging, Third Edition. Medical Physics [online]. 2013, 40(7) [cit. 2023-04-27]. ISSN 00942405. Dostupné z: doi:10.1118/1.4811156
- [3] ZČU: radiologieplzen.eu.radiologieplzen.eu [online]. Copyright © 2007 [cit. 27.04.2023]. Dostupné z: <https://radiologieplzen.eu/ke-stazeni/vyukove-materialy/zcu/>
- [4] SONKA, Milan, Vaclav HLAVAC a Roger BOYLE. Image processing, analysis, and machine vision. New York: Chapman & Hall Computing, 1993. Chapman and Hall computing series. ISBN 978-0-412-45570-4.
- [5] Akutne.cz [online]. [cit. 2021-12-10]. Dostupné z: <https://www.akutne.cz/res/publikace/39-trikortik-ln-ub-u-akutn-ho-poran-syndesmy-hlezna.pdf>
- [6] ŠPANĚL, Michal a Vítězslav BERAN. Obrazové segmentační techniky [online]. 2006 [cit. 2020-11-09]. Vysoké učení technické v Brně, Fakulta informačních technologií. Dostupné z: http://www.fit.vutbr.cz/~spanel/segmentace/#_Toc125769331
- [7] ALLEN, Matthew R.; KROHN, Kelly. Skeletal imaging. In: Basic and applied bone biology. Academic Press, 2014. p. 93-113
- [8] EL-DESOUKI, Mahmoud I.; SHERAFZAL, Mohammad S.; OTHMAN, Saleh A. Comparison of bone mineral density with dual energy x-ray absorptiometry, quantitative ultrasound and single energy x-ray absorptiometry. Saudi medical journal, 2005, 26.9: 1346-1350.
- [9] AZEMINIA, S., N. KARIMI, B. MIRMAHBOUB, S.M.R. SOROUSHMEHR, S. SAMAVI a K. NAJARIAN. Bone extraction in X-ray images by analysis of line fluctuations. In: 2015 IEEE International Conference on Image Processing (ICIP) [online]. IEEE, 2015, 2015, s. 882-886 [cit. 2022-01-13]. ISBN 978-1-4799-8339-1. Dostupné z: doi:10.1109/ICIP.2015.7350926
- [10] Introduction to Trauma X-ray - Fracture description. Radiology Masterclass - [online]. Copyright ©Radiology Masterclass 2007 [Dostupné z: https://www.radiologymasterclass.co.uk/tutorials/musculoskeletal/trauma/trauma_x-ray_page1
- [11] N. Otsu, "A Threshold Selection Method from Gray-Level Histograms," in IEEE Transactions on Systems, Man, and Cybernetics, vol. 9, no. 1, pp. 62-66, Jan. 1979, doi: 10.1109/TSMC.1979.4310076.
- [12] Nachimuthu, Umadevi & Geethalakshmi, S. (2012). Enhanced Segmentation Method for Bone Structure and Diaphysis Extraction from X-ray Images. International Journal of Computer Applications. 37. 10.5120/4589-6531.
- [13] H. P. Ng, S. H. Ong, K. W. C. Foong, P. S. Goh and W. L. Nowinski, "Medical Image Segmentation Using K-Means Clustering and Improved Watershed

- Algorithm," 2006 IEEE Southwest Symposium on Image Analysis and Interpretation, 2006, pp. 61-65, doi: 10.1109/SSIAI.2006.1633722.
- [14] D. Kaur and Y. Kaur, "Various Image Segmentation Techniques: A Review," *Int. J. Comput. Sci. Mob. Comput.*, vol. 3, no. 5, p. 809– 814, date accessed: 18/05/2016, 2014.
- [15] N. Sharma, M. Mishra, and M. Shrivastava, "Colour Image Segmentation Techniques and Issues : an Approach," *Int. J. Sci. Technol. Res.*, vol. 1, no. 4, pp. 9–12, 2012
- [16] S. Saleh Al-amri and N. Kalyankar, "Image Segmentation By Using Edge Detection," *Int. J. Comput. Sci. Eng.*, vol. 02, no. 03, pp. 804– 807, 2010
- [17] "Edge Detection Techniques for Image Segmentation - A Survey of Soft Computing Approaches Edge Detection Techniques for Image Segmentation – A Survey of Soft Computing Approaches," no. May 2014, 2007
- [18] Aja-Fernández S, Curiale A H and Vegas-Sánchez-Ferrero G 2015 A local fuzzy thresholding methodology for multiregion image segmentation *Knowledge-Based Syst.* 83 1–12
- [19] Horenstein RE, Shefelbine SJ, Mueske NM, Fisher CL, Wren TA. An approach for determining quantitative measures for bone volume and bone mass in the pediatric spina bifida population. *Clin Biomech (Bristol, Avon)*. 2015;30(7):748-754. doi:10.1016/j.clinbiomech.2015.04.010
- [20] Chaudhuri, D. & Agrawal, A.. (2010). Split-and-merge Procedure for Image Segmentation using Bimodality Detection Approach. *Defence Science Journal*. 60. 290-301. 10.14429/dsj.60.356.
- [21] Likas, A., Vlassis, N., & J. Verbeek, J. (2003). The global k-means clustering algorithm. *Pattern Recognition*, 36(2), 451–461. doi:10.1016/s0031-3203(02)00060-2
- [22] Rokach, L., & Maimon, O. (n.d.). Clustering Methods. *Data Mining and Knowledge Discovery Handbook*, 321–352. doi:10.1007/0-387-25465-x_15
- [23] Jiang, Y. and Babyn, P. 2004, X-ray bone fracture segmentation by incorporating global shape model priors into geodesic active contours, *Proceedings of the 18th International Congress and Exhibition*, Vol. 1268, pp. 219-224.
- [24] GOLDENBERG, Roman, Ron KIMMEL, Ehud RIVLIN a Michael RUDZSKY. Fast Geodesic Active Contours. In: NIELSEN, Mads, Peter JOHANSEN, Ole Fogh OLSEN a Joachim WEICKERT, ed. *Scale-Space Theories in Computer Vision* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 1999, 1999-4-12, s. 34-45 [cit. 2023-04-23]. *Lecture Notes in Computer Science*. ISBN 978-3-540-66498-7. Dostupné z: doi:10.1007/3-540-48236-9_4BANKMAN, Isaac (ed.). *Handbook of medical image processing and analysis*. Elsevier, 2008.
- [25] SHARMA, Neeraj; AGGARWAL, Lalit M. Automated medical image segmentation techniques. *Journal of medical physics/Association of Medical Physicists of India*, 2010, 35.1: 3.
- [26] NOROUZI, Alireza, et al. Medical image segmentation methods, algorithms, and applications. *IETE Technical Review*, 2014, 31.3: 199-213.

- [27] WITHEY, Daniel J.; KOLES, Zoltan J. Medical image segmentation: Methods and software. In: 2007 Joint Meeting of the 6th International Symposium on Noninvasive Functional Source Imaging of the Brain and Heart and the International Conference on Functional Biomedical Imaging. IEEE, 2007. p. 140-143.
- [28] A C Johnsy, 2018.'Frost Filter Matlab code',<http://www.imageprocessing.com/2018/06/frost-filter.html>
- [29] CHAKI, Jyotismita Chaki a Nilanjan DEY. Intelligent Signal Processing and Data Analysis: A Beginner's Guide to Image Preprocessing Techniques. Boca Raton, Florida: CRC Press, October 25, 2018. ISBN 9780429441134.
- [30] STRANNEBY, Dag. Digital Signal Processing: DSP & Applications. Great Britain: Elsevier, 2001. ISBN 0080491014, 9780080491011.
- [31] DESERNO, Thomas Martin. Biological and Medical Physics, Biomedical Engineering: Biomedical Image Processing. Ilustrované vydání. Berlin: Springer Science & Business Media, 2011. ISBN 0080491014, 9780080491011.
- [32] MALÍKOVÁ, Hana. Základy radiologie a zobrazovacích metod. Druhé, aktualizované vydání. Praha: Univerzita Karlova, nakladatelství Karolinum, 2022. ISBN 9788024651903.
- [33] HAASE, A., Gottfried LANDWEHR, Eberhard UMBACH a Wilhelm Conrad RÖNTGEN. Röntgen Centennial: X-rays in Natural and Life Sciences. Singapur: World Scientific, 1997. ISBN 9810230850, 9789810230852.
- [34] MELIN, Patricia, Claudia I. GONZALEZ, Juan R. CASTRO, Olivia MENDOZA a Oscar CASTILLO. Edge-Detection Method for Image Processing Based on Generalized Type-2 Fuzzy Logic. IEEE Transactions on Fuzzy Systems [online]. 2014, 22(6), 1515-1525 [cit. 2023-04-23]. ISSN 1063-6706. Dostupné z: doi:10.1109/TFUZZ.2013.2297159
- [35] HOSCHKA, Philipp. ERCIM NEWS: Privacy Preserving Computation. ERCIM NEWS: Privacy Preserving Computation. Francie: ERCIM EEIG, 2021, 2021(126), 44. ISSN 0926-4981.
- [36] [online]. . Dostupné z: <https://i.stack.imgur.com/7HFxw.jpg>
- [37] CHAN, T.F. a L.A. VESE. Active contours without edges. IEEE Transactions on Image Processing [online]. 10(2), 266-277 [cit. 2023-04-23]. ISSN 10577149. Dostupné z: doi:10.1109/83.902291
- [38] [online]. . Dostupné z: <http://rtg.fbmi.cvut.cz/rtgobrazky/brzdne.jpg>
- [39] [online]. . Dostupné z: <http://rtg.fbmi.cvut.cz/rtgobrazky/charakteristicke.jpg>
- [40] [online]. . Dostupné z: <https://primadoma.cz/clanek-278263-dny-zdravych-kosti-zjistete-kondici-svych-kosti-zdarma/galerie/2>
- [41] OTSU, Nobuyuki. A Threshold Selection Method from Gray-Level Histograms. IEEE Transactions on Systems, Man, and Cybernetics [online]. 1979, 9(1), 62-66 [cit. 2023-04-27]. ISSN 0018-9472. Dostupné z: doi:10.1109/TSMC.1979.4310076
- [42] CASELLES, Vicent, Ron KIMMEL a Guillermo SAPIRO. International Journal of Computer Vision [online]. 22(1), 61-79 [cit. 2023-04-27]. ISSN 09205691. Dostupné z: doi:10.1023/A:1007979827043

- [43] HELLER, Nicholas, Fabian ISENSEE, Darya TROFIMOVA, Resha TEJPAUL, Nikolaos PAPANIKOLOPOULOS a Christopher WEIGHT, ed. Kidney and Kidney Tumor Segmentation [online]. Cham: Springer International Publishing, 2022 [cit. 2023-04-27]. Lecture Notes in Computer Science. ISBN 978-3-030-98384-0. Dostupné z: doi:10.1007/978-3-030-98385-7
- [44] [online]. . Dostupné z: <https://slovcert.sk/produkt/101-digitalne-ploche-panelove-detektory>
- [45] The essential physics of medical imaging. Second edition. 2002. European Journal of Nuclear Medicine and Molecular Imaging [online]. 2003, 30(12), 1713-1713 [cit. 2023-04-30]. ISSN 1619-7070. Dostupné z: doi:10.1007/s00259-003-1310-2

Seznam příloh

Příloha A:	Dataset 1.....	
Příloha B:	Dataset 2.....	
Příloha C:	Výsledky segmentace	
Příloha D:	Matlab kód pro extrakci ROI spolu se segmentačním modelem	

Dataset 1

Příloha A: *Dataset 1*

Obsahuje 50 ROI fraktur, jedná se o extrahované mat soubory, nahráno v IS Edison.

Příloha B: *Dataset 2*

Obsahuje data variabilních kostí 5 pacientů, jedná se o extrahované mat soubory s rozlišením 151x201, nahráno v IS Edison.

Příloha C: *Výsledky segmentace*

Obsahuje veškeré výsledky, segmentované binární masky, separované fraktury a zdravé kosti a výsledné tabulky společně s grafy. Nahráno v IS Edison.

Příloha D: *Matlab kód pro extrakci ROI spolu se segmentačním modelem*

```
imshow(I)
[X Y]=ginput(1) % Definice počátečních souřadnic

%velikost ROI
V = 200; %výška
S = 150; %šířka
%Výpočet oblasti ROI v závislosti na počátečních souřadnicích
x1 = X - V/2;
y1 = Y - S/2;
ROI_I=rectangle('Position', [x1, y1, V, S], 'EdgeColor', 'r', 'LineWidth', 2); %Tvorba obdélníku pro
zobrazení oblasti v RTG snímku

ROI = imcrop(I,[x1, y1, V, S]); %Extrakce ROI na základě předem definovaných hodnot
figure
imshow(ROI)%Zobrazení ROI

R = ROI;
A=im2uint8(R)
%% Převod RGB=>černobílá
if size(A,3)==3
    A=rgb2gray(A);
end
%% Nastavení kontrastu
I = imadjust(A)
imshow(I)

%% Adaptivní treshholding
I_thres = adaptthresh(I, 0.6);
figure, imshow(I_thres);
title('Adaptive Thresholding');
% Binární dilatace
se = strel('disk',3);%tvorba strukturálního elementu
I_dilate = imdilate(I_thres, se);
figure, imshow(I_dilate);
title('Dilate Image');
```

```

% Binarni eroze
se2 = strel('disk',2);%tvorba strukturálního elementu
I_erode = imerode(I_dilate, se2);
figure, imshow(I_erode);
title('Erode Image');
% Medianovy filtr
I_median = medfilt2(I_erode);
figure, imshow(I_median);
title('Median Filter');
% Otsu thresholding
I_otsu = imbinarize(I_median, graythresh(I_median));
figure, imshow(I_otsu);
title('Otsu''s Thresholding');
% Separace kosti od pozadi
I_bone = I_otsu & I_median;
figure, imshow(I_bone);
title('Separated Bone');
%% Segmentovany obrazek
close all
I_hist=histeq(A)% Nastavení kontrastu
I_2 = I_hist .* uint8(I_bone); % Separace kosti od pozadi
I_4 = A .* uint8(I_bone);
%% Adaptivni treshholding
BW6 = imbinarize(I_2, 'adaptive', 'Sensitivity', 0.620000, 'ForegroundPolarity', 'bright');
% Aktivní kontury
se = strel('disk',4);%tvorba strukturálního elementu
I_3 = imclose(BW6, se);%uzavření masky
BW2 = activecontour(I_2,I_3,10,'edge'); % aktivní kontury s 10 interacemi metoda Edge

% Binární inverze
BW3 = imcomplement(BW2);
% Eroze
se = strel('disk',4);%tvorba strukturálního elementu
BW4 = imerode(BW3, se);
% Dilatace
se = strel('disk',3);%tvorba strukturálního elementu
BW5 = imdilate(BW4, se);
% Aktivní kontury
fraktura_BW = activecontour(I_2,BW5,200,'edge'); % aktivní kontury s 200 interacemi metoda Edge
% Binární inverze
zdrava_kost_BW = imcomplement(fraktura_BW);

%Separace fraktury a zdravé kosti
I_K = I_4 .* uint8(zdrava_kost_BW);
I_F = I_4 .* uint8(fraktura_BW);

```



```

%Binární inverze
BW1 = imbinarize(I_F);
%Otevření masky
se = strel('disk', 2, 0);%tvorba strukturálního elementu
BW10 = imopen(BW1, se);%eroze+dilatace
%Aktivní kontury
BW = activecontour(I_F, BW10, 100, 'Chan-Vese'); % aktivní kontury se 100 iteracemi metoda Chan-
Vese
%Eroze
se = strel('disk', 2, 0);%tvorba strukturálního elementu
BW9 = imerode(BW, se);
%Aktivní kontury
BW = activecontour(I_F, BW9, 100, 'Chan-Vese'); % aktivní kontury se 100 iteracemi metoda Chan-
Vese
%Finální separace
maskedImage1 = I_F;
maskedImage1(~BW) = 0;
BW2 = imcomplement(BW);%Binární inverze
maskedImage2 = I_K .* uint8(BW2);
I_F = I_F .* uint8(BW);

%detekce hran pro zobrazení fraktury v původním obrázku
edges = edge(BW , 'canny');
I_merge = imfuse(A, edges,'blend');
%zobrazení výsledků segmentace
figure;
subplot(1,4,1); imshow(A); title('Originální obrázek');
subplot(1,4,2); imshow(BW6); title('Adaptivni treshholding');
subplot(1,4,3); imshow(BW); title('Aktivní kontury');
subplot(1,4,4); imshow(I_merge); title('Fraktura');
% Prumer maskedImage1=fraktura, maskedImage2=zdravá kost
P1=mean2(maskedImage1); P2=mean2(maskedImage2);
% Median
M1=median(maskedImage1(:));
% Směrodatná odchylka
std_dev = std2(maskedImage1);
%Obvod fraktury
Obvod=regionprops(maskedImage1,'Perimeter');
%Obsah fraktury
Obsah=regionprops(maskedImage1,'Area');
%Tvorba grafu jasových intenzit
[rows, columns] = size(maskedImage1); % Velikost obrazku fraktury

Y = zeros(1, columns); % jasové pole

```

```
for i = 1:columns % smyčka prochazející každým sloupcem
    Y(i) = mean(maskedImage1(:,i)); % výpočet průměrné jasové hodnoty
end

X = 1:columns; % tvorba pole pro pixely

[rows, columns] = size(maskedImage2); % Velikost obrázku zdravé kosti

Y2 = zeros(1, columns); % jasové pole
for i = 1:columns % smyčka prochazející každým sloupcem
    Y2(i) = mean(maskedImage2(:,i)); % výpočet průměrné jasové hodnoty
end

X2 = 1:columns; % tvorba pole pro pixely
%%
figure1 = figure('Name',...
    'Porovnání jasové intenzity fraktury a zdravé kosti','Color',[1 1 1]);
colormap(summer);

% Tvorba os
axes1 = axes('Parent',figure1);
hold(axes1,'on');

set(plot(X, Y),'DisplayName','Fraktura','LineWidth',2);
set(plot(X2, Y2),'DisplayName','Zdravá kost','LineWidth',2);

% Tvorba osy Y
ylabel('Jasová intenzita[-]','FontSize',20,...
    'FontWeight','bold');

% Tvorba osy X
xlabel('Pixely[-]','FontSize',20,...
    'FontWeight','bold');

box(axes1,'on');
hold(axes1,'off');
% Nastavení os
set(axes1,'FontSize',20,'XGrid','on','YGrid','on','FontWeight','bold');
% Tvorba legendy
legend(axes1,'show');
```