

České vysoké učení technické v Praze
Fakulta biomedicínského inženýrství
Katedra biomedicínské techniky

NÁVRH ŘEŠENÍ PRO VČASNOU IDENTIFIKACI DEFEKTŮ PRSNÍCH IMPLANTÁTŮ

Disertační práce

Ing. Barbora Mašková

Kladno, listopad, 2024

Doktorský studijní program: Biomedicínská a klinická technika

Studijní obor: Biomedicínská a klinická technika

Školitel: doc. Ing. Martin Rožánek, Ph.D.

PROHLÁŠENÍ

Prohlašuji, že jsem disertační práci s názvem Návrh řešení pro včasnou identifikaci defektů prsních implantátů vypracovala samostatně a použila k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k disertační práci.

Nemám závažný důvod proti užití tohoto školního díla ve smyslu § 60 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.

V Kladně dne 15.11.2024

.....

Ing. Barbora Mašková

PODĚKOVÁNÍ

Ráda bych poděkovala svému školiteli doc. Ing. Martinu Rožánkovi, Ph.D., za odborné vedení a pomoc při zpracování disertační práce. Dále bych chtěla vyjádřit poděkování Ing. Miroslavu Vavrouškovi, Ph.D., za jeho odborné rady a konzultace. Poděkování patří také MUDr. Josefu Bártovi za konzultace a poskytnutí dat, bez nichž by tato práce nemohla vzniknout.

V neposlední řadě bych ráda poděkovala svému manželovi, rodině a blízkým přátelům za jejich podporu.

Disertační práce byla podpořena grantem Studentské grantové soutěže ČVUT v Praze číslo SGS22/132/OHK4/2T/17.

ABSTRAKT

Návrh řešení pro včasnou identifikaci defektů prsních implantátů

Augmentace prsu představuje rostoucí trend v oblasti estetické a rekonstrukční chirurgie. V roce 2023 bylo celosvětově provedeno více než 1,8 milionu těchto zákroků, což představuje přibližně 12 % všech estetických chirurgických zákroků. Přestože augmentace prsu poskytuje estetické výhody, je spojena také s rizikem závažných komplikací, mezi něž patří ruptura implantátu. Prevalence ruptur prsních implantátů může dosahovat až 77 %, a proto je včasná a přesná diagnostika klíčová pro zajištění bezpečnosti pacientek. Mezi diagnostické metody patří ultrazvuk, mamografie a magnetická rezonance (MRI). Americká FDA doporučuje pravidelnou kontrolu implantátů pomocí MRI, nicméně v České republice jednotný diagnostický postup zatím chybí.

Na základě literární rešerše byla provedena analýza diagnostických metod pro hodnocení prsních implantátů a jejich efektivity při detekci ruptur, která zahrnuje nejen přehled diagnostických metod, ale hlavně porovnání efektivity z hlediska senzitivity a specifity. Dále byly popsány a charakterizovány ruptury na MRI. Tyto kroky byly klíčové pro naplnění cíle disertační práce. Cílem práce bylo navrhnout možný algoritmus pro poloautomatickou detekci ruptur prsních implantátů založený na neuronových sítích.

Pro výzkum byla poskytnuta plně anonymizovaná data pacientek s intrakapsulární rupturou prsních implantátů i bez ní. Data byla anotována ve spolupráci s lékařem radiologem, a následně bylo natrénováno několik modelů s použitím sítí ResNet-18, ResNet-50 a Xception s různým nastavením hyperparametrů a augmentačními technikami. Pro zvýšení přesnosti detekce byla použita metoda ensemble learning.

Podařilo se navrhnout algoritmus poloautomatické detekce intrakapsulárních ruptur prsních implantátů, který v 95,66 % případech správně detekoval rupturu a v 88,89 % identifikoval případy, u nichž ruptura nenastává. Jako hlavní metrika pro výběr modelu byla použita průměrná přesnost pixelu ve snímku (ACC_{mf}), která dosahovala 95,37 %. Tento algoritmus by mohl zefektivnit diagnostiku a sloužit radiologovi jako druhý názor. Vzhledem k absenci guidelineů v České republice byl navíc navržen postup pro hodnocení prsních implantátů, který by uživatelkám prsních implantátů mohl pomoci při prevenci a diagnostice při vzniklých symptomech.

Klíčová slova

Prsní implantát, ruptura, magnetická rezonance, zpracování obrazu, neuronové sítě

ABSTRACT

The Design for Early Identification of Breast Implant Rupture

Breast augmentation represents a growing trend in aesthetic and reconstructive surgery. In 2023, more than 1.8 million of these procedures were performed worldwide, accounting for approximately 12 % of all aesthetic surgical interventions. While breast augmentation offers aesthetic benefits, it is also associated with the risk of serious complications, including implant rupture. The prevalence of breast implant ruptures can reach up to 77 %, making early and accurate diagnosis crucial for ensuring patient safety. Diagnostic methods include ultrasound, mammography, and magnetic resonance imaging (MRI). The U.S. FDA recommends regular MRI checks for implants; however, a standardized diagnostic procedure still needs to be improved in the Czech Republic.

Based on a literature review, diagnostic methods for assessing breast implants and their effectiveness in detecting ruptures were analyzed. This analysis included an overview of diagnostic methods and a comparison of their sensitivity and specificity. Additionally, ruptures were described and characterized on MRI. These steps were critical to achieving the objective of the dissertation. The aim was to propose an algorithm for semi-automatic detection of breast implant ruptures based on neural networks.

For the research, fully anonymized data from patients with and without intracapsular breast implant ruptures were provided. The data were annotated in collaboration with a radiologist, and several models were trained using ResNet-18, ResNet-50, and Xception networks with various hyperparameter settings and augmentation techniques. An ensemble learning method was applied to enhance detection accuracy.

A semi-automatic detection algorithm for intracapsular breast implant ruptures was successfully proposed. The algorithm correctly detected ruptures in 95.66 % of cases and identified non-rupture cases in 88.89%. The primary metric for model selection was the mean accuracy of pixels in the image (ACC_{mf}), which reached 95.37 %. This algorithm could streamline diagnostics and serve as a second opinion for radiologists. Furthermore, given the absence of guidelines in the Czech Republic, a procedure for evaluating breast implants was proposed to assist implant users in preventing and diagnosing symptoms that may arise.

Keywords

Breast implant, rupture, magnetic resonance imaging, image processing, neural networks

Obsah

Seznam symbolů a zkratk.....	8
Seznam tabulek	10
Seznam obrázků	11
1 Úvod	13
2 Problematika prsních implantátů	14
2.1 Anatomie prsu z pohledu prsních implantátů.....	14
2.2 Augmentace prsu implantáty.....	16
2.2.1 Prsní implantát.....	16
2.3 Komplikace spojené s prsními implantáty	18
2.3.1 Kapsulární kontraktura	18
2.3.2 Ruptura	19
2.3.3 Anaplastický velkobuněčný lymfom.....	20
2.4 Bezpečnost prsních implantátů.....	21
2.4.1 Neaktivní chirurgické prostředky ISO 14607: Prsní implantáty	21
2.5 Kritéria vhodnosti pro diagnostiku prsních implantátů.....	24
2.6 Cíle disertační práce	25
3 Zobrazovací metody prsních implantátů.....	26
3.1 Ultrazvuk.....	27
3.2 Mamografie	29
3.3 Magnetická rezonance.....	30
3.3.1 Magnetická rezonance s nízkým polem	30
3.4 Hodnocení ruptury prsního implantátu pomocí zobrazovacích metod	32
3.4.1 Souhrn studií.....	37
3.5 Zpracování obrazu v diagnostice prsních implantátů.....	38
4 Ruptury prsního implantátu.....	39
4.1 Mechanismy vzniku ruptur implantátu	40
4.2 Charakterizace projevů ruptur na magnetické rezonanci	41
4.2.1 Vyšetřovací protokol MRI prsních implantátů.....	44
5 Metody	45
5.1 Sběr a zpracování dat	46

5.1.1	Dataset	46
5.2	Architektura neuronových sítí	49
5.3	Trénování modelu	50
5.3.1	Hyperparametry	50
5.3.2	Augmentace	51
5.4	Vyhodnocení modelu	53
6	Výsledky.....	57
6.1	ResNet-18.....	58
6.2	ResNet-50.....	60
6.3	Xception	62
6.4	Kombinace modelů	64
6.5	Návrh diagnostického postupu	65
7	Diskuze.....	66
8	Závěr	70
	Seznam použité literatury	71
	Příloha A: Rozhodnutí etické komise.....	80
	Příloha B: Struktura neuronových sítí	82
	Příloha C: Výsledky.....	83
	Příloha D: Ukázka výstupů z algoritmu	92

Seznam symbolů a zkratek

Seznam zkratek

Zkratka	Význam
ACR	American College of Radiology (Americká radiologická společnost)
ASPS	American Society of Plastic Surgeons (Americká společnost plastických chirurgů)
Adam	Adaptive Moment Estimation (Optimalizátor)
ASIA	Autoimunitní/zánětlivý syndrom indukovaný adjuvans
BI-ALCL	Breast Implant Associated Anaplastic Large Cell Lymphoma (Velkobuněčný lymfom vyskytující se ve spojitosti s prsními implantáty)
CSV	Comma Separated Values (Typ souboru)
CT	Computed Tomography (Výpočetní tomografie)
ČR	Česká republika
DBIR	Dutch Breast Implant Registry (Národní holandský registr prsních implantátů)
DECT	Dual-energy Computed Tomography (Výpočetní tomografie s duální energií)
DICOM	Digital Imaging and Communications in Medicine (Datový standard)
DNN	Deep Neural Network (Hluboká neuronová síť)
FDA	Food and Drug Administration (Americký úřad pro kontrolu léčiv)
FP	False Positive (Falešně pozitivní)
FN	False Negative (Falešně negativní)
GPU	Graphics Processing Unit (Grafický procesor)
ISO	International Organization for Standardization (Mezinárodní organizace pro normalizaci)
IZ	Ionizující záření
JPEG	Joint Photographic Experts Group (Formát pro ukládání fotografií)
LMLO	Left Mediolateral Oblique
LF-MRI	Low-Field Magnetic Resonance Imaging (Magnetická rezonance s nízkým polem)
MATLAB	Matrix Laboratory
MDR	Medical Devices Regulation (Evropské nařízení o zdravotnických prostředcích)
MG	Mamografie
MRI	Magnetic Resonance Imaging (Magnetická rezonance)
PET	Positron Emission Tomography (Pozitronová emisní tomografie)
PET/CT	Hybridní zobrazovací metoda
PDMS	Polydimethylsiloxan
PIP	Poly Implant Prothese
RBF	Radial Basis Functions (Radiální bázová funkce)
RFID	Radio Frequency Identification
RMLO	Right Mediolateral Oblique
ROI	Region of Interest (Oblast zájmu)
SNR	Signal to Noise Ratio (Poměr signálu a šumu)
SÚKL	Státní úřad pro kontrolu léčiv

Zkratka	Význam
SS	Silicone Suppression (Sekvence s potlačením silikonu)
STIR	Short Tau Inversion Recovery (Sekvence s potlačením tuku)
SGDM	Stochastic Gradient Descent with Momentum
SW	Software
TN	True Negative (Skutečně negativní)
TNR	True Negative Rate (Specificita)
TP	True Positive (Skutečně pozitivní)
TPR	True Positive Rate (Senzitivita)
USA	United States of America (Spojené státy americké)
UZ	Ultrazvuk
WS	Water suppression (Sekvence s potlačením vody)
XML	Exstensible Markup Language
3.LF UK	3. Lékařská fakulta Univerzity Karlovy

Seznam tabulek

Tabulka 3.1 Souhrn senzitivity a specificity na základě analyzovaných studií.....	36
Tabulka 4.1 Standardní MRI vyšetřovací protokol prsních implantátů	44
Tabulka 6.1 Model 2Xa: Nastavené hyperparametry	58
Tabulka 6.2 Model 2Xa: Použití augmentačních technik.....	58
Tabulka 6.3 Model 2Xa: Výsledky model.....	58
Tabulka 6.4 Model 5: Nastavené hyperparametry	60
Tabulka 6.5 Model 5: Použité augmentační techniky	60
Tabulka 6.6 Model 5: Výsledky	60
Tabulka 6.7 Model 38Xc: Nastavené hyperparametry	62
Tabulka 6.8 Model 38Xc: Použité augmentační techniky	62
Tabulka 6.9 Model 38Xc: Výsledky	62
Tabulka 6.10 Výsledky kombinovaných modelů	64
Tabulka 6.11 Výsledky vybraných modelů	64
Tabulka C.1 ResNet18: Nastavené hyperparametry a použité augmentační techniky u jednotlivých modelů	83
Tabulka C.2 ResNet18: Výsledky	85
Tabulka C.3 ResNet-50: Nastavené hyperparametry a použité augmentační techniky u jednotlivých modelů	87
Tabulka C.4 ResNet-50: Výsledky	88
Tabulka C.5 Nastavené hyperparametry a použité augmentační techniky u jednotlivých modelů	89
Tabulka C.6 Xception: Výsledky	90
Tabulka C.7 Výsledky kombinovaných modelů	91

Seznam obrázků

Obrázek 2.1 Anatomické zobrazení prsu s umístěním prsního implantátu. Subglandulární uložení prsního implantátu (vlevo), submuskulární uložení prsního implantátu (vpravo) [10].....	15
Obrázek 2.2 Prsní implantáty plněné silikonovým gelem, kulatý (vlevo) a ve tvaru kapky (vpravo).....	17
Obrázek 2.3 Kalcifikované pouzdro před vyjmutím ze zapouzďřeného implantátu (a). Kalcifikované pouzdro po vyjmutí ze zapouzďřeného implantátu s viditelnou deformací (b) [15].....	19
Obrázek 2.4 Ruptura prsního implantátu [20]	20
Obrázek 3.1 UZ snímek neporušeného prsního implantátu.....	28
Obrázek 3.2 UZ snímek prsního implantátu s intrakapsulární rupturou. Stěna implantátu je na více místech porušena, zanořena dovnitř tělesa implantátu, jehož struktura – echogenita je výrazně nehomogenní.	28
Obrázek 3.3 LMLO projekce prsu na mamografii. Na snímku lze vidět extrakapsulární rupturu prsního implantátu (vlevo). RMLO projekce prsu na mamografii. Na snímku lze vidět neporušený prsní implantát (vpravo).	29
Obrázek 4.1 Axiální T2 vážená sekvence water supression MRI. Na snímku lze vidět intrakapsulární rupturu silikonového implantátu vlevo, tzv. teardrop sign.	41
Obrázek 4.2 Axiální T2 vážená sekvence water supression MRI. Na snímku lze vidět intrakapsulární rupturu silikonového implantátu vlevo, tzv. keyhole sign.....	42
Obrázek 4.3 Axiální T2 STIR vážená sekvence MRI. Na snímku lze vidět oboustrannou intrakapsulární rupturu silikonových implantátů, tzv. linquine sign.	43
Obrázek 4.4 Axiální T2 vážená sekvence water supression MRI. Na snímcích lze vidět radiální záhyby.....	43
Obrázek 5.1 Anotace MRI snímků v SW LabelImg.....	46
Obrázek 5.2 Snímek prsního implantátu s intrakapsulární rupturou (vlevo). Oblast zájmu – znak intrakapsulární ruptury (uprostřed). Masky generované ve tvaru elipsy (vpravo).....	48
Obrázek 5.3 Originální snímek prsního implantátu bez použití filtru (vlevo). Snímek prsního implantátu s použitím hranového filtru (vpravo).....	52
Obrázek 5.4 Matice záměn (Confusion Matrix) [74]	53

Obrázek 6.1 Proces trénování neuronové sítě Resnet-18. Na horním grafu lze vidět závislost přesnosti na počtu iterací a na dolním grafu je znázorněna změna ztráty na počet iterací.....	59
Obrázek 6.2 Proces trénování neuronové sítě Resnet-50. Na horním grafu lze vidět závislost přesnosti na počtu iterací a na dolním grafu je znázorněna změna ztráty na počet iterací.	61
Obrázek 6.3 Proces trénování neuronové sítě Xception. Na horním grafu lze vidět závislost přesnosti na počtu iterací a na dolním grafu je znázorněna změna ztráty na počet iterací	63
Obrázek 6.4 Návrh diagnostického postupu žen s prsním implantátem.....	65
Obrázek B.1 Struktura NN ResNet-18	82
Obrázek B.2 Struktura NN ResNet-50	82
Obrázek B.3 Struktura NN Xception.....	82

1 Úvod

Problematika augmentace prsu je v současné době rostoucím trendem. Jedná se o kosmetický zákrok, který je prováděn z důvodů estetických či zdravotních, mnohdy se jedná o rekonstrukci u pacientek s karcinomem prsu. Dle dostupných údajů z roku 2023 bylo celosvětově provedeno více než 1,8 milionu augmentací prsou, což představuje zhruba 12 % všech estetických chirurgických zákroků [1].

Jakožto každý chirurgický zákrok, tak i augmentace prsu s sebou nese několik možných rizik či vážných komplikací, které mohou po augmentaci nastat. Pro diagnostiku možných komplikací spojených s augmentací prsu, tedy zavedením prsního implantátu do těla pacientky, je nezbytné klinické vyšetření, což není pro stanovení správné diagnózy mnohdy dostačující, proto je vhodné použití zobrazovacích metod jako jsou ultrazvuk (UZ), mamografie (MG), magnetická rezonance (MRI) [2, 3].

V případě poškození implantátu hraje včasná diagnostika pacientky klíčovou roli, neboť stav, který v důsledku defektu nastává může být ohrožující na životě. Lotan upozorňuje, že prevalence prasknutí implantátů se pohybuje ve velice širokém rozptýlu, nicméně může dosahovat až 77 %, samozřejmě v závislosti na typu implantátu, jeho životnosti apod. [4]. Rozsáhlost problému ve své studii potvrzuje také Samreen, přičemž v hodnotách prevalence se mírně liší a uvádí 55 % [5]. Brown ve své studii poukazuje na faktory ovlivňující vznik ruptur implantátu, stáří implantátu a dále hraje roli umístění implantátu (subglandulární, submuskulární) [6]. Rovněž mezinárodně uznávané autority apelují na nutnost řešit tento závažný problém, americká FDA (Food and Drug Administration) doporučuje diagnostiku pomocí MRI u žen s prsním implantátem 5–6 let po zavedení implantátů a následně doporučuje pravidelné kontrolní vyšetření každé 2–3 roky [7]. Tuto účinnou, avšak značně nákladnou prevenci připomínkuje Chung, který podtrhuje vysokou finanční zátěž z pohledu plátce [8]. V České republice (ČR) je přístup k tomuto problému zatím velice konzervativní a není k dispozici jednotný a autoritami schválený postup pro diagnostiku možného defektu prsního implantátu u pacientek pomocí zobrazovacích metod.

Disertační práce se zaměřuje na analýzu použití vhodných zobrazovacích metod pro hodnocení prsních implantátů. Zobrazovací metody mají spoustu výhod, ale i nevýhod a jednou z nich je zpracování velkého souboru snímků radiologem. Interpretace dat vyžaduje značnou expertízu, což může být nejen časově náročné ale i subjektivní. Proto si práce klade za cíl vytvoření algoritmu pro poloautomatickou detekci ruptur prsních implantátů s využitím neuronových sítí. Následně bude navržen postup hodnocení prsních implantátů.

2 Problematika prsních implantátů

Kapitola se zaměřuje na komplexní analýzu problematiky prsních implantátů z různých úhlů pohledu. Kapitola je zaměřena na anatomii prsu, klíčové aspekty augmentace prsu, potenciální komplikace spojené s prsními implantáty a bezpečnost. Prsní implantáty představují významný pokrok v oblasti plastické a rekonstrukční chirurgie, umožňující ženám zlepšit nejen estetický vzhled, ale i obnovit symetrii po mastektomii. Ačkoliv se jedná o rutinní zákrok, jehož popularita neustále roste, má řadu specifických problémů a otázek.

2.1 Anatomie prsu z pohledu prsních implantátů

Augmentace prsu je chirurgický zákrok, který zahrnuje vložení implantátu do prsu za účelem zvětšení jeho objemu, tvaru nebo symetrie. Prsní implantát může být implantován dvěma způsoby, a to pod prsní žlázu, či pod prsní sval (Obrázek 2.1). Pro porozumění možnostem a důsledkům implantace prsních implantátů, je důležité pochopit základní anatomii prsu.


Prs (mamma) je párový orgán tvořící vyklenutí na přední straně hrudníku, kde je obsažena prsní žláza (glandula mammae). Prs dospělé ženy se vyskytuje v několika tvarových typech: plochý, polokulovitý, hruškovitý a posléze ochablý prs. Prs je uložen vertikálně od 3. do 6. žebra a horizontálně sahá od parasternální čáry do přední axilární čáry. Rozměr prsu závisí na podnebí a věku, průměrný rozměr je kolem 12 cm. Kůže prsu je světlá, tenká a bohatě inervovaná. Na vrcholu prsu je dvorec (areola mammae) v průměrné velikosti 3–5 cm, v graviditě je větší. Dvorec je pigmentovaný, růžový, hnědý až temně hnědý, v závislosti na typu a pigmentaci ženy. Uprostřed dvorce je prsní bradavka (papilla mammae), která je zpravidla mírně vyvýšená, nebo někdy lehce vkleslá.

Prsní žláza je největší kožní žlázou. Zhruba 2/3 mléčné žlázy jsou přilehnuty na velký prsní sval (musculus pectoralis major). V pubertě u dívek dochází k rozvoji prsní žlázy, kdežto u chlapců dochází k zakrnění. Vyvinutou prsní žlázu tvoří zhruba 20 laloků, jejich vývody se spojují v mlékovody (ductus lactiferi). Mlékovody ústí na hrotu bradavky. Na funkci žlázy se podílí prolaktin a luteinizační hormon [9].

Umístění implantátu pod prsní žlázu se nazývá jako subglandulární, tzn. umístění mezi prsní tkání a hrudním svalem. Další volbou, je umístění implantátu pod prsní sval. Díky této technice jsou implantáty vloženy do kapsy v hrudníku, které se nachází pod prsním svalem [10, 11].

Volba zavedení implantátů závisí nejen na požadovaném výsledku, ale také na tloušťce podkožního tuku. Pokud pacientka požaduje, aby prsy vypadaly přirozeně a nebyl viditelný okraj implantátu v horní části prsu, je zvoleno umístění pod prsní sval,

zvláště pokud pacientka má malou prsní žlázu bez větší vrstvy podkožního tuku. Nad prsní sval se implantát umísťuje především v případě, jestliže pacientka chce, aby prsy byly výraznější a také, když má pacientka silnější vrstvu podkožního tuku. Pro hodnocení podkožního tuku je výhodné použít pinch test, při kterém se v horní části prsu vytvoří kožní řasa. U obou přístupů je snaha chirurga neporušit mlékovody, tudíž v případě těhotenství není narušeno kojení [12, 13] .



Obrázek 2.1 Anatomické zobrazení prsu s umístěním prsního implantátu. Subglandulární uložení prsního implantátu (vlevo), submuskulární uložení prsního implantátu (vpravo) [10]

2.2 Augmentace prsu implantáty


Použití prsních implantátů představuje nejjednodušší metodu pro augmentaci prsu a je první volbou na mnoha pracovištích. První zmínky o kosmetické úpravě prsu byly koncem 19. století, kdy Robert Gersuny zvětšení prováděl pomocí parafínových injekcí, které způsobovaly nežádoucí reakce, tudíž se od nich ustoupilo. V roce 1895 český rodák Vincenz Czerny provedl zdařilou augmentaci pomocí exstirpovaného lipomu. Dále byla snaha zvětšení na základě přenosu tukové tkáně z oblasti hýždí či břicha, od těchto technik se postupně ustupovalo, důvodem byly deformity v oblasti prsu. Vzhledem k nenaplnění očekávání u výše uvedených technik se znovu začalo uvažovat o použití cizích materiálů k augmentaci prsu. Do prsu byl aplikován tekutý silikon, hydron, polyester a další materiály, avšak i tady výsledky nebyly dobré. V polovině 20. století se implantovaly prsní implantáty s řadou materiálů, např. vlna, skleněné kuličky, parafín, včelí vosk aj. Tyto materiály však vytvářely nejen tvrdá prsa a jejich nepřirozený tvar, ale mnohdy docházelo k fatálním komplikacím. V 50. a 60. letech 20. století začalo docházet k vývoji polymerních prsních implantátů, dále začal být objevován silikonový kaučuk. První silikonové implantáty byly vyrobeny a aplikovány v chirurgické praxi v roce 1963 Thomasem Cronienem a Frankem Gerowem, což lze považovat za revoluční převrat v estetické chirurgii prsu. Jejichž základní princip je používán doposud.

Postupem času však docházelo k postupnému vývoji prsních implantátů, aby se zmírnily některé nežádoucí reakce, jako je únik obsahu implantátu do těla pacientky, opouzdření implantátu s následnou kontrakcí pouzdra, ruptura, nepřirozený tvar a další komplikace. Za velký přínos je považována změna hladkého povrchu implantátů za povrch texturovaný. V současné době mají největší uplatnění silikonové implantáty plněné gelem či fyziologickým roztokem [11, 13].

2.2.1 Prsní implantát

V současné době je u prsních implantátů plněných silikonovým gelem či fyziologickým roztokem použito silikonové kaučukové pouzdro [4, 15]. Silikony obsažené v prsních implantátech jsou polymerované siloxany, nejčastěji je používán polydimethylsiloxan (PDMS) [16]. Látka PDMS je základem pro gel, který vyplňuje implantát, ale také pro plášť implantátu. Jedná se o olejovitou lepkavou kapalinu s viskozitou, která se zvyšuje s rostoucí délkou řetězce [15]. Fyziologický roztok je považován za bezpečnější, a to kvůli schopnosti rychlého vstřebání do lidského těla. I přes to, je častěji využíváno silikonového gelu, protože se chováním a vlastnostmi podobá přirozené prsní tkáni. Pokud je gelový implantát vystaven deformaci vlivem nepoškozujícího zatížení a toto zatížení je odstraněno, gel se časem vrátí do svých původních rozměrů [17]. Plášť je vyroben z kapalných složek a amorfního oxidu

křemičitého (SiO_2), který se přidává k výrobě vysoce účinného silikonového kaučuku pro mnoho účelů, včetně zlepšení mechanických vlastností [15]. Povrch může být chemicky modifikován či potažen, aby se omezilo prosakování nebo se předešlo adhezi tkáně [18].



Obrázek 2.2 Prsní implantáty plněné silikonovým gelem, kulatý (vlevo) a ve tvaru kapky (vpravo).

Na trhu je mnoho typů prsních implantátů, které se liší v řadě fyzikálních vlastností, jako je tvar (kulatý a tvar kapky), velikost, výplň a povrchová struktura [7]. Povrch implantátu může být drsného či hladkého charakteru. Drsný povrch zlepšuje integraci mezi prsní tkání a implantátem, kdežto hladký povrch slouží k volnému pohybu implantátu, čímž je pohyb prsu s prsním implantátem přirozenější. Výběr implantátů je jedním z nejdůležitějších předpokladů dobrého výsledku operace a závisí na preferencích pacientky a lékaře [8].

2.3 Komplikace spojené s prsními implantáty

Přestože je použití prsních implantátů považováno obecně za bezpečné, stejně jako u jiných invazivních zákroků, nese s sebou určitá rizika vzniku komplikací. Tato kapitola se zaměřuje na identifikaci možných komplikací, které mohou nastat jak krátkodobě, tak dlouhodobě po operaci.

Mezi časně komplikace lze zařadit hematom, serom, infekce kolem implantátu, chybné umístění, posun či rotace, obnažení a chybná volba velikosti implantátu. Mezi nejčastější vyskytující se pozdní komplikace patří kapsulární kontraktura kolem implantátu (kapsulární fibróza), ruptura, infekce, deformace a zvlnění či pozdní serom [13, 18].

Výše uvedené komplikace lze dělit na lokální a systémové. Mezi lokální komplikace patří asymetrie, kapsulární kontraktura, extruze, hematom, posunutí či špatné umístění implantátu, hematom, zvrásnění, infekce, nekróza, ruptura, serom a anaplastický velkobuněčný lymfom asociovaný s prsním implantátem (BI-ALCL) [19–22]. Mezi systémové komplikace patří autoimunitní/zánětlivý syndrom indukovaný adjuvans (ASIA) [18].

Klinicky nezjistitelnou komplikací je možný průnik materiálu přes membránové mikropóry neporušeného pláště implantátu. Uniklý materiál může pronikat do dalších částí těla, nejčastěji regionálních lymfatických uzlin. Pokud nedojde k rozsáhlému průniku, není možné tekutinu detekovat pomocí zobrazovacích metod [3].


2.3.1 Kapsulární kontraktura

Nejčastější lokální komplikací je kapsulární kontraktura nebo také kapsulace. Kolem implantátu se vytvoří pouzdro, jedná se o přirozenou reakci imunitního systému jako na každé cizí těleso (Obrázek 2.3). V některých případech kapsule přeroste normální formu do tlusté vláknité kapsle. Tato komplikace se projevuje bolestí na hrudi, kontrakcí a deformací prsu [23, 24]. Důsledkem je ztvrdnutí nebo deformace implantátu, a v závažných případech může dojít ke snížení schopnosti správně zobrazit prsní tkáň včetně implantátu během vyšetření [26]. Podle závažnosti je kapsulární kontraktura klasifikována Backerovou stupnicí (stupeň I.–IV.), která je však považována za velice subjektivní metodu hodnocení [27].

Kapsulární kontraktura se dělí do čtyř klinických stádií:

- I. Implantát není hmatný a není viditelný.
- II. Implantát je hmatný, ale není viditelný.
- III. Implantát je hmatný i viditelný.
- IV. Prs je tvrdý, bolestivý, deformovaný [14].

Pro přesnou diagnostiku je nutné použít také zobrazovací metody, při kterých je možno vidět změnu obrysu implantátu, který se stává asymetrickým.




Obrázek 2.3 Kalcifikované pouzdro před vyjmutím ze zapouzdřeného implantátu (a). Kalcifikované pouzdro po vyjmutí ze zapouzdřeného implantátu s viditelnou deformací (b) [15]

2.3.2 Ruptura

Ruptura, nebo-li prasknutí implantátu (Obrázek 2.4) je další často zmiňovanou komplikací implantace prsu. Ruptury mohou být klasifikovány jako intrakapsulární nebo extrakapsulární. Častěji se udává výskyt intrakapsulární ruptury, při které nedochází k makroskopickému úniku materiálu za neporušenou kapsli, uniklý materiál je uzavřený ve vláknité tobolce. Dle autora Lotana a kol. intrakapsulární ruptura představuje nejběžnější typ prasknutí, který zahrnuje 77–89 % všech případů [5]. Zatímco makroskopický únik silikonu vně vláknitého pouzdra se nazývá extrakapsulární ruptura. Na základě analýzy studií je značný vysoký rozptyl prevalence prasknutí, který se pohybuje v rozmezí od 3 % do 77 %, což značí vysoký rozptyl [4].

U ruptury implantátu s fyziologickým roztokem je následkem únik izotonického fyziologického roztoku, který je neškodný a po čase je tělem reabsorbován. Kdežto u ruptury implantátu se silikonovou výplní, silikon může cestovat lymfatickým systémem do regionálních a vzdálených lymfatických uzlin [5], což může vést k dalším komplikacím [16, 28].

Mezi symptomy ruptury lze zahrnout změnu tvaru nebo velikosti prsu, otoky, bolest, záněty, zvrásnění a vzácně i infekci. Ruptura může být mnohdy asymptomatická, a to díky tomu, že uvolnění silikonu může zůstat uzavřené ve vláknité tobolce obklopující samotný implantát. Vzhledem k tomu, že ruptura nemusí být klinicky diagnostikována, je důležitá včasná diagnostika na základě zobrazovacích metod [29]. Mezi příčiny vzniku ruptur lze zařadit výrobní vady, mechanické poškození, iatrogenní poškození, ale také stárnutí implantátu [4].



Obrázek 2.4 Ruptura prsního implantátu [20]

2.3.3 Anaplastický velkobuněčný lymfom

Anaplastický velkobuněčný lymfom (BI-ALCL) vzniklý ve spojitosti s prsním implantátem je vzácným podtypem non-Hodgkinova lymfomu. Faktory vzniku BI-ALCL zahrnují genetické predispozice, bakteriální kontaminaci (chronický zánět), vylučování mikročástic a vlastnosti povrchu implantátu, zejména u texturovaných implantátů [21]. K červnu 2023 bylo americkým úřadem pro kontrolu potravin a léčiv (FDA) hlášeno 1264 případů BI-ALCL (pacientky s bilaterálním BI-ALCL se počítají jako 2 případy), z toho bylo 918 případů s texturovaným povrchem implantátu [30].

Nejčastějším projevem je periprotetická tekutina (serom). Z tohoto důvodu se nejprve provádí odběr tekutiny z okolí implantátu [23]. V případě potvrzení diagnózy jsou vyžadována zobrazovací vyšetření jako MRI, výpočetní tomografie (CT), pozitronová emisní tomografie (PET) nebo hybridní metoda PET/CT. MG se pro diagnostiku BI-ALCL primárně nepoužívá, důvodem je nízká specifita [31].

2.4 Bezpečnost prsních implantátů

Legislativa a bezpečnost prsních implantátů je klíčovou oblastí, která zajišťuje ochranu zdraví pacientek a kvalitu zdravotnických prostředků. V Evropské unii podléhají prsní implantáty regulaci podle Nařízení o zdravotnických prostředcích (MDR 2017/745), které stanovuje požadavky na bezpečnost, klinické hodnocení, sledovatelnost a povinné certifikace. Výrobci musí zajistit, že jejich produkty splňují stanovené standardy a procházejí pravidelnými inspekcemi a kontrolami kvality. Poskytovatel zdravotních služeb je povinen poskytnout pacientce kartu s informacemi o zavedeném implantátu, což zvyšuje kvalitu a bezpečnost [32].

Za účelem vyhodnocení a zvýšení kvality chirurgických zákroků a zvýšení informovanosti o komplikacích jsou zakládány registry, např. v roce 2015 byl založen národní holandský registr prsních implantátů (DBIR). Jedná se o jeden z prvních celosvětově fungujících registrů prsních implantátů [26]. V rámci ČR neexistuje registr prsních implantátů, nad bezpečností dozoruje Státní ústav pro kontrolu léčiv (SÚKL), který spolupracuje s dalšími mezinárodními orgány v rámci sledování a hodnocení rizik spojených s těmito prostředky.

2.4.1 Neaktivní chirurgické prostředky ISO 14607: Prsní implantáty

Pro bezpečnost prsního implantátu je nutno splnit požadavky dle stanovených předpisů a norem. Dle ISO (International Organization for Standardization) jsou prsní implantáty řazeny do skupiny implantabilních zařízení. Norma ISO 14607 je zaměřena na Neaktivní chirurgické prostředky a specifikuje zvláštní požadavky na prsní implantáty. Dokument klade požadavky na funkčnost, materiál, design, balení, sterilizaci a informace poskytované výrobcem.

Výroba a testování materiálů podléhá systému řízení kvality. V případě použití jiného materiálu než silikonu, musí výrobce stanovit vhodné zkušební metody a kritéria přijatelnosti k prokázání bezpečnosti implantátu. Během stanovování mechanických vlastností je zohledněno: prodloužení (%) při přetržení, pevnost v tahu (MPa) při přetržení, modul (MPa) při 100% prodloužení, tvrdost, relativní hustota, měrná hmotnost, pevnost v roztržení (kN/m). Mechanické testy slouží k testování integrity obalu implantátu, pomocí prodloužením obalu, tahem obalu. Dále je nutné otestovat pevnost spojů obalu. Odolnost obalu se testuje na základě únavového testu a dále zkouškou odolnosti proti nárazu. Také je testována kompatibilita mezi plnicím materiálem a obalem implantátu, kdy je prováděna zkouška soudržnosti, hodnocena penetrace gelu a difúzní zkouška. Dále je hodnocen objem implantátu, který by měl být v rozmezí $\pm 2,5$ % objemu, který je uveden na štítku implantátu. Na základě chemických zkoušek je testován povrch implantátu.

Před uvedením výrobku na trh se provádí klinické hodnocení. Cílem klinického hodnocení je odhad výskytu případných komplikací (ruptura, kapsulární kontraktura aj.). Norma definuje potřebné informace, které výrobce musí uvést v příbalové informaci a na štítku. Štítek musí obsahovat rozměry a plnicí objem. Výrobce musí poskytnout základní informace pro pacientky o účincích implantátu při použití diagnostické zobrazovací metody, dále informace o životnosti a funkčnosti implantátu. Na životnost implantátu má vliv několik faktorů jako je proces implantace, mechanické vlivy a zdravotní stav pacientky, tudíž ji není možné přesně určit.

Dle normy je testováno:

Testování integrity obalu, které je prováděno pomocí rámu a je provedena zkouška tahem. Implantát musí být pevně sevřen na obou stranách a je prodlužován konstantní rychlostí 500 mm/min, prodloužení je min. 450 %. Při testování pevnosti v tahu je vzorek prodloužen cca na 300 %, v tomto stavu setrvá 3 minuty následně je uvolněn a vrácen do výchozí polohy. V případě testování pevnosti švu je nutné odebrat takovou část, aby v referenční oblasti byl šev. Vzorek je umístěn do rámu a dochází k jeho prodlužování na hodnoty 100–300 %, v tomto stavu se udržuje po dobu 10 s. Po provedení zkoušek se vypracuje zpráva s popisem obsahu vzorku implantátu: název, výrobce, sériové číslo, datum provedení, výsledky zkoušek, testování a identifikace osoby, která testy prováděla.

Testování mechanických vlastností implantátu, které je provedeno na základě únavové zkoušky a zkouškou odolnosti proti nárazu. Únavová zkouška je provedena pomocí přístroje, který generuje střídavý pohyb v mobilní desce a pracuje na frekvenci 3,3 Hz. Implantát je umístěn mezi dvě protilehlé desky a je držen tlakovou silou, kde následně vzniká deformace střídavým pohybem jedné z desek. Testování je prováděno při teplotě 23 °C a upravením kompresní síly na 50 N. Tento test musí probíhat $6,5 \times 10^6$ cyklů a po skončení testu nesmí být žádné známky prasknutí, následně je zpracován protokol o výsledné zkoušce. Testování odolnosti vůči nárazu je založeno na vertikálním poklesu specifické hmotnosti na implantát. Implantát je vystaven nárazové síle, která je úměrná hmotnosti implantátu. Výška pádu je dána vztahem $H = 0,95m + 144$, kde m je hmotnost implantátu (g), H je výška (mm). Po dokončení testování nesmí být patrné prasknutí pláště implantátu. Dále je nutné vypracovat závěrečnou zprávu o zkoušce, která obsahuje údaje o implantátu, popis zkušebního zařízení, včetně výsledků zkoušky.

Testování soudržnosti silikonového gelu, které se provádí pouze pro implantáty plněné silikonovou výplní. Gel obsažený v implantátu je vložen do přístroje, dolním otvorem přístroje se po dobu 30 min nechá samovolně protékat. Následně se kontroluje, zda se nějaký gel oddělil od objemu a je měřena vyčnívající délka gelu z přístroje. Také je testována penetrace gelu, kdy se gel naplní do nádoby a nechá se vytvrdit.

Do vytvrzeného vzorku je na doraz zaveden hloubkoměr a z číselníku se odečte výsledek penetrace (mm).

Difuze u implantátů je hodnocena metodou in vitro. Zkouška se provádí ponořením implantátu do simulované tělní tekutiny při 37°C. Následně je po stabilizování uvolněného gelu provedena analýza emisní spektrometrie. Vlastnosti povrchu implantátu jsou hodnoceny povrchovou metrologií. Z měření je získána velikost nebo průměr pórů, počet vrcholů, výška vrcholů, průměrná vzdálenost mezi morfologickými znaky [10].

2.5 Kritéria vhodnosti pro diagnostiku prsních implantátů

Kapitola obsahuje souhrn kritérií vhodnosti Americké radiologické společnosti (ACR) pro diagnostiku prsních implantátů (aktualizace proběhla v roce 2023). Hodnocení prsních implantátů a přístup k zobrazovacím technikám se může lišit v závislosti na typu implantátu, věku pacientky, přítomnosti příznaků a riziku vzniku komplikací. Tyto postupy jsou určeny k posouzení integrity implantátů a nejsou náhradou za standardní screening karcinomu prsu. Následující doporučení vycházejí z aktuálních klinických pokynů pro hodnocení prsních silikonových implantátů.

1. Doporučení pro pacientky se silikonovými prsními implantáty:

- Pacientky bez příznaků (implantace <5 let): Pro tuto skupinu se zobrazování nedoporučuje, pokud nejsou přítomny žádné symptomy.
- Pacientky bez příznaků: Pro pacientky jakéhokoli věku se silikonovými implantáty se doporučuje první zobrazování 5 až 6 let po implantaci. Následná zobrazovací vyšetření jsou doporučena v intervalu 2 až 3 let po prvním vyšetření v případě, že bylo negativní. V těchto případech je vhodné UZ vyšetření prsu a MRI bez použití kontrastu.
- Pacientky s podezřením na komplikace: V případech podezření na komplikace je vhodné provést MRI prsu bez kontrastu, které poskytuje přesné zobrazení a umožňuje identifikaci ruptur nebo jiných komplikací spojených s implantáty.

2. Specifická doporučení pro pacientky s rizikovými faktory nebo příznaky:

- Pacientky mladší 30 let se silikonovými implantáty a nevysvětlitelnou axilární adenopatií: Pro tyto pacientky, které mají otok lymfatických uzlin v podpaží, se doporučuje UZ vyšetření prsu k vyloučení malignit nebo jiných patologických změn.
- Pacientky ve věku 30 let a starší se silikonovými implantáty a nevysvětlitelným zvětšením lymfatických uzlin: V těchto případech se doporučuje kombinace UZ prsu, digitální diagnostické tomosyntézy a diagnostické MG pro detailní hodnocení stavu prsních implantátů a okolních tkání.
- Pacientky s podezřením na BI-ALCL spojený s prsními implantáty: U pacientek, u kterých je podezření na BI-ALCL, ale nejsou známky karcinomu prsu nebo zánětu, může být UZ vyšetření prsu adekvátním nástrojem pro počáteční posouzení [32-33].

2.6 Cíle disertační práce

Cílem disertační práce s názvem Návrh řešení pro včasnou identifikaci defektů prsních implantátů je **navrhnout algoritmus pro poloautomatickou detekci časných intrakapsulárních ruptur na základě hodnocení integrity silikonových prsních implantátů**. Pro splnění cíle je třeba provést dílčí kroky:

- 1) Analýza použití diagnostických metod pro hodnocení prsního implantátu.
 - Přehled diagnostických metod.
 - Porovnání efektivity diagnostických zobrazovacích metod (senzitivita, specifita).
 - Identifikace optimální metody pro detekci ruptur.
- 2) Charakterizace a popis ruptur.
- 3) Ověřit funkčnost algoritmu detekce ruptur.
 - Návrh a implementace algoritmu pro poloautomatickou detekci ruptur na základě snímků z magnetické rezonance.
 - Ověření funkčnosti algoritmu na datech s rupturovanými a neporušenými implantáty.
 - Vyhodnocení přesnosti algoritmu.
- 7) Návrh diagnostického postupu pro vyšetření pacientek s prsním implantátem.

3 Zobrazovací metody prsních implantátů

Cílem této kapitoly je souhrn aktuálního stavu používaných zobrazovacích metod u žen se silikonovým prsním implantátem a dále analýza jejich účinnosti při hodnocení implantátu na základě sledovaných parametrů senzitivity a specificity.

Dle rešerše literatury bylo zjištěno, že nejčastěji vyskytující se komplikace spojené se zavedením prsního implantátu jsou způsobeny kapsulární kontrakturou a rupturou implantátu. Ačkoli hodnocení možných komplikací je primárně řízeno příznaky pacientky, včetně změny tvaru implantátu, velikosti či pevnosti prsu. Většina pacientek s výskytem ruptury neprojevuje významné příznaky, jedná se o tzv. tichou rupturu. Z toho vyplývá, že fyzikální vyšetření je pro diagnostiku ruptury nedostatečné a pro správnou a včasnou diagnostiku je důležité použití zobrazovacích metod [2].

Americký úřad FDA doporučuje diagnostiku silikonových prsních implantátů pomocí zobrazovacích metod, je upřednostňována MRI, za účelem screeningu ruptury implantátu. FDA předpokládá první vyšetření 5–6 let po augmentaci a poté každé 2–3 roky. Guidelines FDA odráží výzkumy, které naznačují, že prevalence ruptur má tendenci narůstat se stářím implantátu [2]. Americká společnost plastických chirurgů (ASPS) a ACR jsou v souladu s doporučením FDA [35]. Co se týče evropských guidelines, například ve Francii je využívána screeningová metoda UZ, která je prováděna po 4,7, a 10 letech [30]. V ČR nejsou k dispozici žádná doporučení, jak postupovat u diagnostiky prsních implantátů.


3.1 Ultrazvuk

Ultrazvuk (UZ) je primární vyšetřovací metodou pro diagnostiku prsních implantátů, využívá mechanického vlnění. V mamární diagnostice je používaná frekvence v rozpětí 6–18 MHz, což umožňuje zobrazení měkkých tkání a implantátů. Princip UZ zobrazení spočívá ve vysílání pulzních vln do tkáně elektroakustickým měničem založeným na piezoelectrickém jevu. Vlny se odrážejí v závislosti na akustické impedanci různých struktur a jsou zpětně detekovány elektroakustickým měničem, který z nich vytváří obraz [36].


Normální vzhled implantátu na UZ (Obrázek 3.1) ukazuje tři neporušené echogenní vrstvy, které představují vnitřní a vnější stěnu pouzdra implantátu a vazivové pouzdro [29]. U diagnostiky intrakapsulární ruptury je třeba hledat tyto znaky:

- Subkapsulární znak, značí paralelní linie;
- Znak štafle (Stepladder sign), značí více vrstev rovnoběžných linií v implantátu. Tento znak je velmi podobný křivočarým liniím (Linguine) který, lze detekovat na MRI. Tento znak je důležité nezaměňovat s radiálními záhyby, což je normální nález;
- Znak sněhové bouře (Snowstorm sign), představuje přítomnost volných silikonových kapiček v synoviální tekutině [37].

Dle dostupných studií UZ disponuje vysokou specificitou, ale ne příliš vysokou senzitivitou (Tabulka 3.1). Pokud je dle UZ podezření na rupturu implantátu, pravděpodobnost skutečného prasknutí je vysoká, naopak pokud na UZ není viditelná žádná ruptura, je stále možnost výskytu intrakapsulární ruptury [38]. UZ je dostupnou, rychlou, levnou a snadno proveditelnou metodou. Dle studie autorů Chunga a kol., ve které byla provedena analýza nákladů a přínosů bylo zjištěno, že z hlediska nákladů je optimální diagnostikovat rupturu UZ s následným zobrazením MRI [8]. Výsledky studie potvrzuje i analýza nákladové efektivity provedená v diplomové práci v podmínkách ČR [39]. Úskalím UZ je fakt, že provedení vyšetření a následné hodnocení je závislé na subjektivním hodnocení lékaře [40].



Obrázek 3.1 UZ snímek neporušeného prsního implantátu.




Obrázek 3.2 UZ snímek prsního implantátu s intrakapsulární rupturou. Stěna implantátu je na více místech porušena, zanořena dovnitř tělesa implantátu, jehož struktura – echogenita je výrazně nehomogenní.

3.2 Mamografie

Mamografie (MG) je metoda využívající ionizující záření s nízkou energií (napětí rentgenky se pohybuje přibližně od 20 do 40 kV), je vhodná pro zobrazování měkkých tkání. Tato metoda může být použita i u pacientů s prsními implantáty, je třeba provádět šetrnou kompresi a mimo základní projekce se doporučuje využít speciální projekce. Speciální projekce, tzv. Eklundova technika (odsunutí implantátu dozadu a nahoru) umožňuje zobrazit větší část prsní žlázy.

Při zobrazení prsu je obecně nejčastěji používanou metodou screeningová MG (jedná se o rutinní screeningovou metodu karcinomu prsu u žen ve věku od 45 let), která může poskytnout prvotní informace o problému s prsním implantátem. Je třeba zdůraznit, že v rámci screeningu prsu je primárním účelem detekce karcinomu prsu, nikoliv hodnocení implantátu. Další možností je diagnostická MG, která je cílena na ženy, které mají příznaky, např. hmatný nález. Ačkoli je MG pro zobrazení prsního implantátu nejméně citlivá metoda pro detekci intrakapsulární ruptury, může být užitečná při diagnostice extrakapsulární ruptury a to v případě uniknutí silikonu z fibrózní kapsule do parenchymu prsu (Obrázek 3.3) [40].



Obrázek 3.3 LMLO projekce prsu na mamografii. Na snímku lze vidět extrakapsulární rupturu prsního implantátu (vlevo). RMLO projekce prsu na mamografii. Na snímku lze vidět neporušený prsní implantát (vpravo).

3.3 Magnetická rezonance

Metoda MRI funguje na principu silného elektromagnetického pole, konvenční MRI metody se pohybují od 1–3 T. MRI je efektivní zobrazovací metodou pro hodnocení integrity stěny a homogenity obsahu implantátů díky vysokému prostorovému rozlišení, absenci ionizujícího záření (IZ) a schopnosti zesílit, nebo potlačit signál vody, silikonu a tuku [41].

Vyšetření prsního implantátu se provádí v poloze vleže na břiše a je použita oboustranná mamární cívka. Pro hodnocení prsních implantátů se doporučují T2 vážené sekvence s potlačením tuku inverzním pulzem (STIR) v kombinaci se spektrálním potlačením vody nebo silikonu, a to ve dvou rovinách (T2 Silicone Suppression Axial/Sagittal, T2 Water Suppression Axial/Sagittal) [42].

MRI na rozdíl od UZ umožňuje vyhodnotit radiální záhyby a odlišit je od ruptury, dále přehledněji zobrazí zadní stěnu implantátu. Rozpoznání normálních nálezů snižuje výskyt falešně pozitivních nálezů. Provádí se nativně, ale v případě podezření na karcinom prsu jsou aplikovány gadoliniové kontrastní látky.

Nejpřesnější a nejspolehlivější diagnostická metoda pro hodnocení integrity prsního implantátu je právě MRI. Jednoznačně disponuje nejvyšší senzitivitou a specificitou. Nevýhodou jsou vysoké náklady, nižší dostupnost a delší čekací lhůty. Dle odborníků z praxe se MRI provádí buď za přítomnosti klinických příznaků, nebo pro účely screeningu detekci tiché ruptury, jak je doporučováno FDA [43].

3.3.1 Magnetická rezonance s nízkým polem

Magnetická rezonance s nízkým polem (LF-MRI), je definována jako technologie s nízkou magnetickou indukcí pod 1 T. V posledních letech se zvyšuje snaha využití LF-MRI, které byla používána zejména v počátcích vývoje technologie MRI. V současné době jsou pro klinické využití standardem zařízení s indukcí 1,5 a 3 T, zejména kvůli tomu, že LF-MRI vykazovala nižší kvalitu obrazu (nižší SNR). Díky pokroku v oblasti zpracování obrazu pomocí umělé inteligence se však postupně zvyšuje snaha o klinické využití LF-MRI.

Komerční zájem vedl ke schválení několika magnetických rezonancí s nízkým polem úřadem FDA. První na trh uvedla svůj přístroj společnost Hyperfine, konkrétně MRI 0,064 T Hyperfine Swoop (pro vyšetření hlavy). Následovaly MRI 0,066 T Promaxo (pro vyšetření prostaty), MRI 0,5 T Synaptive Evry (pro intraoperační MRI) a MRI 0,55 T Siemens Magnetom Free.Max (pro vyšetření celého těla).

Zatímco konvenční přístroje s vysokým polem dominují trhu na základě určitých parametrů, existují dva hlavní faktory, které vytvářejí příležitosti pro současné systémy s nízkým polem. Prvním faktorem jsou nižší pořizovací a provozní náklady, druhým jsou technologické inovace, které vedou ke zlepšení kvality obrazu. Díky vývoji hardwaru a softwaru (SW) MRI přístrojů, včetně nových cívek, inovativních pulzních sekvencí a pokročilého zpracování měřených signálů (například pomocí technik hlubokého učení), je možné šum v obraze redukovat jinými metodami než zvýšením magnetické indukce, což vede ke zlepšení celkové kvality výsledného obrazu [44].

Autoři Frankel a kol. ve své studii popisují hodnocení prsních implantátů pomocí LF-MRI. V rámci studie byly získány snímky z MRI Toshiba America, 0,064 T u symptomatických a asymptomatických pacientek. Ze skupiny 38 pacientek s prsními implantáty, které podstoupily MRI byly vybrány 4 pacientky na základě různorodosti příznaků spojených s implantací.

U pacientky 1 byly na snímcích MRI dobře viditelné neporušené obrysy implantátu i intenzita signálu výplně implantátu, což vedlo k diagnostice neporušeného implantátu. I přes tento výsledek se pacientka rozhodla pro explantaci kvůli přetrvávajícím potížím (bolesti, erytém, otoky), přičemž při explantaci byl implantát také potvrzen jako neporušený. Pacientka 2 měla implantát s výrazným zvlněním, který byl rovněž diagnostikován jako intaktní. Přesto si pacientka nechala implantát chirurgicky odstranit kvůli nepohodlí. I zde byl implantát neporušený, ale byla přítomna kapsulární kontraktura IV. stupně. U pacientky 3 byla na MRI diagnostikována intrakapsulární ruptura. U pacientky 4 byly na snímcích uvnitř silikonu identifikovány dvě kruhové oblasti s vyšší intenzitou signálu, které představovaly kapky volné tekutiny v silikonu, což vedlo k diagnostice intrakapsulární ruptury.

Hodnocení implantátů pomocí MRI umožňuje snadno rozlišit vodu, silikon a prsní tkáň, což je klíčové pro správnou diagnostiku u žen s podezřením na rupturu implantátu. Ze sledovaných případů vyplývá, že vyšetření LF-MRI je dostatečné pro identifikaci radiálních záhybů a deformit. Pomocí tohoto vyšetření lze plně zhodnotit integritu implantátu, fibrózní kapsulu a dokonce i zadní stěnu implantátu, kterou nelze adekvátně posoudit při běžných zobrazovacích metodách jako je MG a UZ [44, 10].

3.4 Hodnocení ruptury prsního implantátu pomocí zobrazovacích metod

Goldammer a kol. hodnotili účinnost zobrazovacích metod při diagnostice silikonových prsních implantátů. Do studie byl zahrnut vzorek 234 pacientek (367 implantátů), bylo potvrzeno 144 ruptur (31,06 %) prsních implantátů. U MG byla udávána senzitivita 70 %, specificita 93 %. U diagnostiky UZ byla udávána senzitivita 84 % a specificita 90 %. Nejcitlivější zobrazení bylo metodou MRI, kde byla udávána senzitivita 99 % a specificita 78 %. Nejméně senzitivní metodou je MG, což znamená, že téměř v 1/3 se nepodaří diagnostikovat rupturu. Vyšetření MRI vykazuje nejvyšší senzitivitu. Pokud jde o specificitu, tak MG je nejvhodnější pro vyšetření intaktních implantátů [2].

Autoři Rukanskiené a kol. hodnotili přesnost UZ při diagnostice ruptury silikonového prsního implantátu. Řada studií porovnává hodnocení integrity prsního implantátu, nicméně přesnost vyšetření uváděná různými autory se liší, tj. od 50 % [46] do 94 % [47]. Do studie bylo zahrnuto 76 žen se 152 prsními implantáty. Při vyšetření UZ bylo 91 implantátů intaktních a 61 implantátů s podezřením na rupturu. Po chirurgickém vyjmutí implantátů bylo zjištěno, že bylo 58 implantátů prasklých. MRI prsu bylo provedeno v 17,1 % případů (n=26), z nich bylo 14 intaktních, zatímco u 12 případů byla prokázána ruptura. Studie ukázala, že UZ je velmi přesný, senzitivita je 98,3 % a specificita 89,2 %. Vzhledem k cenové dostupnosti oproti MRI autoři studie doporučují provádět každý rok po augmentaci UZ. V případě symptomů či podezření na rupturu, doporučují provedení MRI [48].

Autoři Satii a kol. posuzovali, zda je UZ účinným diagnostickým nástrojem při hodnocení ruptury implantátu, jako referenční metoda byla použita MRI. Velikost vzorku byla n = 30 pacientek (60 implantátů), které podstoupily UZ a následně MRI. UZ odhalil 4 intrakapsulární ruptury a 1 extrakapsulární. Senzitivita a specificita UZ byla 94 % a 55 %. Diagnostika MRI odhalila že ruptura byla intrakapsulární u 8 pacientek a extrakapsulární u 1 pacientky. Senzitivita a specificita MRI byla 98 % a 91 %. Autoři studie došli k závěru, že UZ lze použít jako vyšetřovací metodu první volby při hodnocení prsních implantátů. Při detekci intrakapsulární ruptury je vyžadováno vyšetření MRI [47].

Ve studii autora Bogettiho a kol. bylo zahrnuto 30 symptomatických pacientek, které podstoupily mono či bilaterální rekonstrukci prsou (celkem 51 silikonových implantátů). Byla provedena diagnostika ruptury pomocí UZ u 32 (62,7 %) implantátů, 19 implantátů bylo neporušeno. Senzitivita a specificita UZ byla 90 % a 80 %. Na základě použití metody MRI bylo diagnostikováno prasknutí u 30 (58,8 %) implantátů, zatímco 21 implantátů bylo neporušených. Senzitivita a specificita MRI byla 87 % a 85 %. Přestože je MRI považováno za zlatý standard zobrazovacích metod,

UZ představuje efektivní, neinvazivní, levnou a snadno dostupnou metodu hodnocení integrity implantátu. Autoři studie navrhuji k detekci ruptur první volbu vyšetřením UZ u symptomatických pacientek [49].

Autoři Samreen a kol. hodnotili jednotlivé zobrazovací metody, UZ, MG a MRI. Zobrazovací metoda MG vykazuje senzitivitu 11–69 % pro detekci ruptury. Extrakapsulární rupturu lze na MG rozpoznat denzitou silikonu v prsní tkáni. Intrakapsulární rupturu mnohdy na základě MG rozpoznat nelze proto je vyžadováno zobrazení pomocí zobrazovacích metod UZ nebo MRI. UZ udává senzitivitu 30–75 %. Klíčovým znakem na UZ při vyšetření intrakapsulární ruptury je tzv. „steplader“, kde jsou zaznamenány hyperechoické linie odpovídající zhroucené části pláště. U extrakapsulární ruptury je typickým znakem tzv. „snowstorm“. Metoda MRI je považována za nejpřesnější při hodnocení ruptur, kde je udávána senzitivita 72–94 %. U intrakapsulární ruptury je typickým znakem na MRI tzv. teardrop (vzhled slzy), kdežto extrakapsulární ruptura se jeví únikem silikonu mimo fibrotickou kapsulu [5].

Autoři Sinha a kol., provedli studii, kde cílem bylo zhodnotit přesnost diagnostiky ruptury implantátu UZ ve srovnání MRI. Autoři do studie zahrnuli 46 pacientek, které podstoupily vyšetření UZ a MRI. Vyšetřením UZ bylo detekováno 15 ruptur se senzitivitou 94 %, specificitou 75 %. Vyšetřením MRI detekovalo rupturu ve 20 % případech (n=16/79). Autoři došli k závěru, že UZ je vhodnou screeningovou metodou pro vyšetření ruptur implantátu, oproti MRI je nákladově efektivnější. Při podezření ruptury na UZ je doporučeno diagnózu potvrdit pomocí diagnostické metody MRI [50].

Autoři Stivala a kol. provedli studii, kde bylo zahrnuto 175 symptomatických i asymptomatických pacientek (n=242 silikonových implantátů). Diagnóza intrakapsulární ruptury byla ověřena chirurgickým vyjmutím implantátu. Před chirurgickým zákrokem byly porovnány nálezy ze zobrazovacích metod MG, UZ a MRI. Mezi 242 implantáty bylo potvrzeno 35 ruptur. Je uváděno 22 falešně pozitivních a 15 falešně negativních výsledků diagnostiky ruptur. MG byla nejpřesnější, byla udávána 82,8% senzitivita a 99,5% specificita. Zobrazovací metoda UZ byla nejméně přesnou metodou, byla udávána 82,8% senzitivita a 93,2% specificita. Naopak MRI byla nejcitlivější metodou, zde byla udávána 91,4% senzitivita a 96,6% specificita. Při srovnání diagnostické účinnosti zobrazovacích metod autoři dospěli k závěru, že UZ v kombinaci s MRI může být užitečnou metodou pro mladé pacientky. Ve studii byla MG označena vysokou specificitou a přesností, mohla by být užitečná v kombinaci s MRI u pacientek ve věku nad 40 let [51].

Při hodnocení integrity silikonového prsního implantátu autoři studie Glazebrook a kol. u UZ uvádí senzitivitu 50–77 %, specificitu 55–84 %. U MRI senzitivitu 74–100 %, specificitu 55–84 %. V případě kontraindikace MRI, Johnson [52] pro hodnocení integrity prsních implantátů provedli CT vyšetření s duální energií

(DECT). Byly vyšetřeny dvě pacientky z toho u jedné z nich byla detekována extrakapsulární i intrakapsulární ruptura, která následně byla potvrzena vyšetřením UZ i MRI. Zatímco MRI je dle studií doporučovanou technikou pro hodnocení ruptur, DECT se jeví jako slibné v hodnocení konkrétnějšího rozsahu extrakapsulární ruptury, např. postižení lymfatických uzlin. DECT může sloužit jako alternativní technika pro rychlou diagnostiku [53].

Autoři Lotan a kol. měli za cíl ve své studii posoudit diagnostickou přesnost zobrazovacích metod při detekci ruptury. Do studie bylo zahrnuto 57 žen, celkem 109 implantátů a z toho u 74 implantátů bylo podezření na rupturu. Celkem 55 pacientek bylo doporučeno k diagnostice pomocí UZ a MRI, 2 pacientky byly diagnostikovány na základě klinického vyšetření. Na základě diagnostických metod došlo ke zjištění zvýšené míry prasknutí levých prsních implantátů, 61 % prasklých implantátů bylo levostranných. U 67 implantátů podezřelých k ruptuře byla použita diagnostika UZ, z toho u 61 implantátů byla na základě UZ diagnostikována ruptura. Senzitivita UZ byla 98 % a specifická 24 %. U 16 implantátů byla ruptura během chirurgického vyjmutí vyloučena. U dalších 40 implantátů podezřelých k ruptuře bylo doporučeno vyšetření MRI před chirurgickým zákrokem. Ruptura byla zjištěna u 27 implantátů s pozitivní diagnostikou na základě MRI, z toho 6 implantátů bylo během provedení chirurgického zákroku nalezeno jako neporušené. Senzitivita MRI byla 100 % a specifická 54 %. Ze závěru autorů vyplývá, že by diagnostika pomocí MRI by měla být metodou první volby [4].

Autoři studie Wong a kol. shrnují diagnostiku změn prsního implantátu pomocí MRI. Dle autorů diagnostické vyšetření metodou MRI, ve srovnání s metodami MG a UZ, má nejvyšší senzitivitu a specifitu pro detekci ruptury implantátu. Senzitivita zobrazovací metody MRI je udávána v rozmezí 80–90 % a specifická 90–97 % [3].

Dle studie autorů Juanpere a kol. je senzitivita MG v rámci diagnostiky ruptury silikonových implantátů variabilní, ale vždy nízká, pohybuje se mezi 25–30 % a specifická je 68 %. Přestože MG a UZ jsou standardními prvními kroky při diagnostice prsu, MRI je nejspolehlivější metodou pro charakterizaci implantátů díky vysokému rozlišení, kontrastu mezi implantátem a měkkými tkáněmi. MRI v diagnostice ruptur disponuje nejvyšší senzitivitou a to v rozmezí 80–90 % a specifitou 90–97 %, čemuž přispívá použití sekvencí, které mohou potlačit nebo zdůraznit signál ze silikonu [54].

Autoři studie Song a kol. provedli metaanalýzu studií zabývajících se diagnostickou přesností zobrazování MRI pro detekci ruptur silikonového prsního implantátu. Autoři dle klíčových slov našli 1175 studií v dané problematice, z toho bylo dle stanovených kritérií zahrnuto 21 studií. Většina studií se zaměřovala na symptomatické pacientky (MRI n=10; UZ n=10). Souhrnná analýza napříč studiemi naznačuje vysokou přesnost MRI se senzitivitou 87 % a specifitou 89,9 %. Většina studií se zabývala pouze

symptomatickými pacientkami, což vede k vyšší prevalenci ruptury implantátu a vyšším odhadům diagnostické přesnosti. Nicméně mnohé z publikovaných studií využívajících zobrazování MRI ne UZ k detekci ruptury silikonového prsního implantátu mají nedostatky v metodologii, což může vést k nesprávné interpretaci výsledků [55].

Cílem studie autora Hölmicha a kol. bylo zhodnotit účinnost MRI při diagnostice prsního silikonového implantátu. Sledovaný vzorek tvořil 64 žen (n=118 implantátů). Pomocí metody MRI bylo 66 implantátů diagnostikováno jako prasklé a 43 jako neporušené. 27 implantátů bylo diagnostikováno jako extrakapsulární ruptura. Po chirurgickém vyjmutí implantátů byla potvrzena ruptura u 65 implantátů. Při kategorizaci možných ruptur byla na MRI 1 falešně pozitivní a 9 falešně negativních diagnóz ruptury, což značí senzitivitu 89 % a specifitu 97 %. Dle studie autoři dospěli k závěru, že vyšetření MRI je vysoce přesné pro identifikaci ruptury implantátu, což značí vysoká senzitivitou a specifitu. Je nutno podotknout, že hodnocení snímku musí být založeno na přítomnosti dobře definovaných kritérií [56].

V tabulce (Tabulka 3.1) je uveden souhrn senzitivity a specifity na základě analyzovaných studií jednotlivých diagnostických metod.

Tabulka 3.1 Souhrn senzitivity a specificity na základě analyzovaných studií

Autor, rok	Zobrazovací metoda	Senzitivita [%]	Specificita [%]
Goldammer, 2021 [2]	MG	70	93
	UZ	84	90
	MRI	99	78
Rukanskienė, 2021 [48]	UZ	98,3	89,2
	MRI	100	93,3
Satti, 2020 [47]	UZ	94	55
	MRI	98	91
Bogetti, 2018 [49]	UZ	90	80
	MRI	87	85
Samreen, 2018 [5]	MG	11–69	–
	UZ	30–75	–
	MRI	72–94	–
Sinha, 2017 [50]	UZ	94	75
Stivala, 2017 [51]	MG	82,8	99,5
	UZ	82,8	93,2
	MRI	91,4	96,6
Glazebrook, 2016 [53]	UZ	50–77	55–84
	MRI	74–100	55–84
Lotan, 2016 [4]	UZ	98	24
	MRI	100	54
Wong, 2016 [3]	MRI	80–90	90–97
Juanpere, 2011 [54]	MG	25–30	68
	MRI	80–90	90–97
Song, 2011 [55]	UZ	30–77	55–91
	MRI	87	89,8
Hölmich, 2005 [56]	MRI	89	97

3.4.1 Souhrn studií

Riziko vzniku ruptury se zvyšuje se stářím implantátu, životnost implantátu je dána výrobcem a pohybuje se v rozmezí 10–16 let. Plastičtí chirurgové by měli úzce spolupracovat s radiology, kteří jsou schopni rozpoznat normální vzhled běžně používaných implantátů na různých zobrazovacích metodách.

Diagnostickeou metodou první volby při hodnocení integrity implantátů je UZ. Dle některých dostupných studií má UZ ve srovnání s MRI relativně nízkou senzitivitu a specifitu, a to v rozmezí 30–98,3 %; 24–93,2 %. U UZ dochází k obtížnému hodnocení zadní stěny a zadní části tkáně v důsledku silného útlumu ultrazvukových vln silikonem. Při podezření ruptury na základě UZ je dle analyzovaných studií doporučována indikace MRI pro úplné vyloučení ruptury.

MG je diagnostickeou a screeningovou metodou při hodnocení prsní tkáně a má omezenou roli při hodnocení implantátů zejména při detekci intrakapsulární ruptury. Dle analýzy studií se senzitivita pohybuje v rozmezí 11–82,8 %, což značí vysoký rozptyl a specifita v rozmezí 68–99,5 %.

MRI má mezi zobrazovacími metodami nejvyšší senzitivitu a specifitu, dle dostupných studií se pohybuje v rozmezí 72–100 %; 55–99,5 % při hodnocení integrity prsního implantátu. Navíc na základě MRI lze hodnotit tvar implantátu nebo migraci gelu, kdy pomocí různých sekvencí lze rozlišovat rozdíl mezi vodou či tukem. Správná diagnostika je důležitá před provedením chirurgického zákroku, tedy při odstraňování implantátu z těla pacientky. I přesto, že je MRI z klinického hlediska nejvíce efektivní oproti ostatním zobrazovacím metodám (UZ, MG, DECT), tak se dle analyzovaných studií mnohdy jedná o metodu poslední volby, což je v rozporu s doporučením FDA. Důvodem je fakt, že UZ je levnější a dostupnější metodou [3, 48, 49].

Mezi analyzovanými studiemi je patrný výskyt významné heterogenity senzitivity a specifity jednotlivých i stejných zobrazovacích metod. Tato variabilita může být způsobena rozdíly v technickém provedení vyšetření, interpretací výsledků, různou kvalifikací a zkušeností odborníků, kteří vyšetření provádějí. Jednotlivé studie se liší v závěrech a doporučeních ohledně nejvhodnějších vyšetřovacích metod pro detekci ruptur. Zatímco některé studie upřednostňují použití MRI pro její vysokou rozlišovací schopnost a detekci komplikací spojených s prsními implantáty, jiné zdůrazňují výhody UZ, zejména jeho dostupnost a nižší náklady.

Tato práce se na základě analýzy současného stavu zaměřuje na použití MRI při vyšetření integrity silikonových prsních implantátů. Metoda MRI je doporučována FDA a má vysokou rozlišovací schopnost, což je zásadní pro přesné hodnocení stavu prsních implantátů a okolních struktur.

3.5 Zpracování obrazu v diagnostice prsních implantátů

Diagnostika snímků ze zobrazovacích metod je pro radiologa časově náročná. Velkou roli hrají zkušenosti lékaře z klinické praxe, protože i malé abnormality mohou signalizovat komplikace a mohou být zaměňovány s radiálními záhyby, které představují normální nález. V současné době je obecně v diagnostice populární využití metod neuronových sítí (NN) při zpracování obrazu, které mohou významně podpořit práci lékařů tím, že urychlují analýzu snímků, mohou zvýšit přesnost diagnostiky a přispívat k identifikaci problémů již v raném stádiu.

V diagnostice prsních implantátů byly již v minulosti použity aplikace NN u UZ metod. Autoři Salchenberger a kol. ve své studii zkoumali potenciál využití NN s radiální bázovou funkcí (RBF), k diagnostice prsních implantátů na základě UZ nálezů. Studie se zúčastnily symptomatické a asymptomatické pacientky (n=78 prsních implantátů), u kterých bylo provedeno chirurgické odstranění a následně byly analyzovány ultrazvukové nálezy pomocí NN (zpětné propagace a RBF) metodou "leave-one-out". Výkonnost těchto modelů byla porovnána s diagnostikou radiologů pomocí ROC křivek. Výsledky ukazují, že NN mají potenciál zlepšit diagnostiku ruptur prsních implantátů, zejména v případech, kdy je identifikace ruptury obtížná nebo neurčitá. Nejlepší výsledky byly dosaženy, když byl kombinován přístup neuronových sítí s diagnostikou lékařů. Studie naznačuje, že NN mohou sloužit jako užitečný nástroj pro lékařské rozhodování a mohou přispět k lepší diagnostické přesnosti [56, 57].

Další využití NN v souvislosti s prsními implantáty představili autoři Kim a kol. Cílem studie bylo ověřit proveditelnost použití modelu hlubokého učení k rozpoznání typů textury prsních implantátů na základě UZ snímků a tím podpořit diagnostiku BI-ALCL. Do studie bylo retrospektivně zahrnuto 19 502 UZ snímků. Byl použit model hlubokého učení Resnet-50. Model hlubokého učení dosáhl vysoké přesnosti při rozlišování typů textury implantátů (AUROC až 0,98). Model prokázal schopnost identifikovat klíčové oblasti na UZ snímcích a vykazoval vysokou robustnost vůči nejistotám. Výsledky studie naznačují, že hluboké učení by mohlo být užitečné pro klinické rozhodování a zlepšení diagnostiky BI-ALCL [59].

4 Ruptury prsního implantátu

Bezpečnost, odolnost, dlouhodobá stabilita, estetika prsních implantátů a jejich vliv na zdraví pacientek jsou předmětem zájmu a obav. Události kolem prsních implantátů značky Poly Implant Prosthesis (PIP) vyvolaly rozsáhlé debaty mezi lékařskou komunitou a uživatelkami těchto implantátů. Jednou z nejzávažnějších komplikací spojených s prsními implantáty jsou ruptury. Míra ruptury se během 10 let pohybuje od 1 % do 35 %, avšak její přesné diagnostika je stále obtížná kvůli nejednotným postupům screeningového vyšetření [60].

Ruptura implantátu představuje nejen estetický problém, ale může také vést k zánětlivým reakcím a dalším zdravotním komplikacím v důsledku úniku silikonového gelu z implantátu do okolní tkáně (lymfadenopatie vyvolaná silikonem [61], syndrom respirační insuficience [62, 63], chronická plicní embolie [63, 64] atd.). Šíření silikonu a následná poškození jsou často nevratná kvůli neschopnosti organismu eliminovat částice silikonu z těla [16].

Z těchto důvodů je důkladná diagnostika a včasná detekce ruptur klíčová pro minimalizaci rizik a zajištění optimální péče o pacientky. Vzhledem k tomu, že MRI se ukázala být jednou z nejpresnějších metod pro detekci ruptur implantátů, je tato disertační práce zaměřena na využití MRI při diagnostice této komplikace.

4.1 Mechanismy vzniku ruptur implantátu

Několik studií o odolnosti pláště prsních implantátů došlo k závěru, že na vznik ruptur má vliv několik faktorů, jako je iatrogenní poškození během chirurgického zákroku, stárnutí materiálu, kapsulotomie, biomechanická poškození (např. automobilové nehody [65], sport [66] a výrobní vady [60]).

Autoři Handel a kol. přezkoumali data značek Mentor a Allergan týkající se příčin ruptur a zjistili, že 50–54 % ruptur bylo hlášeno jako důsledek poškození chirurgickými nástroji [67].

Zejména u implantátů značky PIP hrály významnou roli faktory jako degradace materiálu a variabilita v procesu návrhu a výroby, což nasvědčuje tomu, že implantáty PIP nebyly vyrobeny v souladu s normami a standardy pro zdravotnické prostředky. Tyto informace vedly k tomu, že regulační orgány a veřejnost začaly tuto značku spojovat s vyšším rizikem ruptur [66, 67].

Ramiao a kol. [68] ve své studii provedli biomechanické testování u explantovaných prsních implantátů PIP (n=11) a kontrolních implantátech (n=5). Nejčastějším důvodem odstranění implantátů byla obava z budoucích komplikací a možného prasknutí. Životnost prsních implantátů je obvykle udávána nad 10 let (120+ měsíců), avšak prevalence ruptur byla zaznamenána při průměrné době implantace 57,36 měsíců (přibližně 5 let), což poukazuje na strukturální problémy a poškození integrity implantátu.


4.2 Charakterizace projevů ruptur na magnetické rezonanci

Ruptura prsního implantátu na MRI se může projevovat různými charakteristickými znaky, jako je například přítomnost volné tekutiny kolem implantátu, deformace obrysů, nebo změny v intenzitě signálu.

Potvrzení ruptur je založeno na detekci níže uvedených příznaků, na jejichž základě, lze diagnózu potvrdit. Jak již bylo zmíněno v předchozí kapitole ruptury mohou být dvojího typu: intrakapsulární a extrakapsulární. Při extrakapsulární ruptuře silikon volně migruje za obal implantátu a fibrosní kapsuli. U intrakapsulární ruptury lze detekovat následující znaky:

Znak slzy (Teardrop Sign)


Jedná se o ohniskovou invaginaci obalu implantátu, kde se stěny vzájemně dotýkají. V kapce je malé množství silikonu, což značí, že je mimo obal (Obrázek 4.1).



Obrázek 4.1 Axiální T2 vážená sekvence water suppression MRI. Na snímku lze vidět intrakapsulární rupturu silikonového implantátu vlevo, tzv. teardrop sign.

Znak klíčové dírky (Keyhole či Nose Sign)


Jedná se o ohniskovou invaginaci obalu, kde se stěny nedotýkají. V této „klíčové dírce“ je malé množství silikonu a zároveň mimo obal implantátu (Obrázek 4.2).



Obrázek 4.2 Axiální T2 vážená sekvence water suppression MRI. Na snímku lze vidět intrakapsulární rupturu silikonového implantátu vlevo, tzv. keyhole sign.


Linquine Sign

Rupturovaný implantát se jeví jako křivočaré linie (Obrázek 4.3).



Obrázek 4.3 Axiální T2 STIR vážená sekvence MRI. Na snímku lze vidět oboustrannou intrakapsulární rupturu silikonových implantátů, tzv. linquine sign.

Příznaky intrakapsulární ruptury je nutné odlišit od normálního skládání pláště implantátu, které může obsahovat tekutinu, což je normální periprotetická tekutina [54]. Často jsou detekovány radiální záhyby, neměly by být zaměňovány s rupturou implantátu. Jedná se o znak, který vede k falešně pozitivním nálezům na MRI (Obrázek 4.4) [28].



Obrázek 4.4 Axiální T2 vážená sekvence water suppression MRI. Na snímcích lze vidět radiální záhyby.

4.2.1 Vyšetřovací protokol MRI prsních implantátů

Pro hodnocení stěny prsního implantátu se používají T2 vážené sekvence STIR (Short Tau Inversion Recovery) s potlačením signálu tuku pomocí inverzního impulzu v kombinaci se spektrálním potlačením silikonu nebo vody (silicone suppression/water suppression).

Sekvence STIR se saturačním impulzem pro silikon obvykle zobrazuje silikon jako silně hypointenzní homogenní strukturu. V případě rozpadu stěny implantátu je homogenita tohoto slabého signálu porušena a zobrazí se (obvykle malé) oblasti vyššího signálu, které odpovídají vniknutím tekutiny. STIR s nasycovacím pulzem pro vodu zobrazí silikon jako jediné hyperintenzní těleso v prsu. Protonový signál v prsu obsažený v molekulách vody i tuku je potlačen. Tato sekvence má nejvyšší senzitivitu pro detekci poruchy integrity stěny implantátu, i když signál silikonu uvnitř implantátu zůstává homogenní.

V praxi není vždy nutné zahrnout všechny sekvence, zejména v případě zjevné ruptury implantátu (např. typické příznaky ruptury). Sagitální SS sekvence se nejčastěji vynechávají. Pokud je to možné, provádějí se SS i WS axiální roviny, aby se poskytly diagnostické informace v rozumném čase.

Tabulka 4.1 Standardní MRI vyšetřovací protokol prsních implantátů

Sekvence	Anatomická rovina	Šířka řezu
T2 STIR SS	Axiální	5 mm
T2 STIR WS	Axiální	5 mm
T2 STIR SS	Sagitální	5mm – pravý implantát
T2 STIR WS	Sagitální	5mm – pravý implantát
T2 STIR SS	Sagitální	5mm – levý implantát
T2 STIR WS	Sagitální	5mm – levý implantát

K sekvencím uvedeným v tabulce (Tabulka 4.1) lze přidat TR sekvenci bez potlačení tuku a s potlačením tuku (např. Dixon) v příčné rovině 3 mm. Tato sekvence zobrazí struktury v okolí implantátu podrobněji, včetně případného výpotku.

5 Metody

Včasná detekce ruptur silikonových prsních implantátů je klíčová pro prevenci komplikací a pro zajištění bezpečnosti pacientek. Na základě rešerše literatury bylo potvrzeno, že MRI má nejvyšší senzitivitu a specificitu pro detekci ruptur prsních implantátů, zejména intrakapsulárních ruptur. Na rozdíl od MG, která se zaměřuje především na hodnocení prsní tkáně a je vhodná zejména pro detekci extrakapsulárních ruptur, nebo UZ, jehož přesnost závisí na zkušenostech lékaře. Metoda MRI poskytuje detailní a spolehlivé zobrazení integrity implantátu.

Automatizace detekce ruptur pomocí metod hlubokého učení (Deep Learning) představuje významný pokrok v oblasti lékařské diagnostiky. V posledních letech se hluboké učení, zejména hluboké neuronové sítě (DNN), staly účinným nástrojem pro analýzu lékařských obrazů, včetně identifikace anomálií, jako jsou nádory, srdeční vady a další. Implementace těchto algoritmů může významně snížit zátěž lékařů, zvýšit přesnost diagnostiky, minimalizovat lidské chyby a sloužit jako „druhý názor“ při rozhodování lékaře.

Tato práce se zaměřuje na návrh algoritmu pro poloautomatickou detekci intrakapsulárních ruptur na MRI obrazech pomocí DNN. Algoritmus je založen na použití neuronových sítí v prostředí MATLAB (The MathWorks, Inc., USA). Cílem této kapitoly je popsat postup sběru a přípravy dat, návrh modelu, jeho trénování a validaci.


5.1 Sběr a zpracování dat

Pro realizaci této disertační práce byla použita anonymizovaná data pacientek s diagnostikovanou intrakapsulární rupturou prsního implantátu i bez ní. Anonymizovaná data byla poskytnuta Klinikou radiologie a nukleární medicíny 3. LF UK Fakultní nemocnice Královské Vinohrady se souhlasem etické komise EK-R/02/0/2021 (Příloha A). Vyšetření byla provedena pomocí MRI s magnetickým polem o síle 1,5 T (Signa, GE HealthCare a Magnetom Sola, Siemens). Byla poskytnuta datová sada obsahující záznamy 30 pacientek v několika sekvencích. Pro následné zpracování byla vybrána axiální sekvence T2 STIR WS z důvodu potlačení signálu tuku a zdůraznění vody, což usnadňuje detekci intrakapsulární ruptury.

5.1.1 Dataset

Data byla poskytnuta ve formátu DICOM (Digital Imaging and Communication in Medicine), který poskytuje jak obrazová data, tak i důležitá metadata vyšetření, jako jsou informace o pacientce a metodě aj. Všechna data byla zdravotnickým zařízením plně anonymizována a zbavena identifikujících informací. DICOM obrazy byly následně převedeny pomocí SW JiveX do formátu JPEG.

Pro účely tréninku modelů bylo nutné data nejprve anotovat, tzn. vyznačit oblasti zájmu (ROI), což je zásadní krok pro dosažení kvalitních výsledků. Proces anotace byl proveden ve spolupráci s lékařem radiologem s praxí v mamární diagnostice 23 let, aby byla zajištěna klinická přesnost identifikace intrakapsulárních ruptur. V SW LabelImg (Obrázek 5.1) radiolog označil všechny ROI (vyznačení ruptury) na snímcích MRI, přičemž každý snímek mohl obsahovat jednu či více oblastí zájmu, nebo se nevyskytovala žádná. Při anotaci byl současně generován XML soubor, který obsahoval souřadnice těchto oblastí ve formě bounding boxů.




Obrázek 5.1 Anotace MRI snímků v SW LabelImg

Pro zpracování anotovaných obrazových dat byl použit skript (P0_createDatabaseRaw), který automatizoval proces výřezu oblastí zájmu z jednotlivých snímků. Skript načítal snímky uložené ve složkách jednotlivých pacientek. Proběhla kontrola souboru region.mat, který obsahuje ROI. Snímky byly oříznuty podle definované oblasti, tedy podle implantátu a uloženy do struktury database. V případech, kdy existovaly odpovídající XML soubory, byly z nich načítány informace o hranicích objektů tzv. bounding boxy, které byly následně porovnány s ROI. Pokud hranice přesahovala nebo částečně překrývala ROI, byla tato skutečnost zaznamenána a provedla se příslušná transformace souřadnic. Po zpracování všech snímků byla data uložena do databáze a všechny nesrovnalosti byly zapsány do logu, který byl exportován do CSV souboru pro další analýzu a byl využit pro odstranění případných nedostatků.

Po zpracování obrazových dat pacientek a jejich výřezů z ROI bylo nutné rozdělit dataset pro trénink, validaci a testování modelů. K tomu byl využit další skript, který automatizoval proces rozdělení dat do příslušných složek a jejich předzpracování. Všechny anotované snímky každé z pacientek byly vybrány do trénovačích, validačních nebo testovací skupiny, aby nedocházelo k ovlivnění věrohodnosti procesu testování v poměru 15:10:5, což zajistilo vyvážené zastoupení pacientek v jednotlivých částech datasetu. Trénovací sada byla použita pro samotné učení modelu, validační sada sloužila k ladění a optimalizaci hyperparametrů a testovací sada poskytla nezávislý soubor pro finální hodnocení výkonu modelu. Toto rozdělení pomohlo zajistit, že model je dostatečně robustní a testovaný na různorodých datech, což snížilo riziko přeučení na tréninkovou sadu.

Další skript (P1_createTrainData) nejenže rozdělil data do příslušných sad, ale také je předzpracoval. Vytvořil adresáře pro obrázky a jejich odpovídající masky, které byly generovány na základě souřadnic tzv. bounding boxů. Obrázky byly filtrovány podle definovaných pravidel a zmenšeny na požadovanou velikost. Masky, generované ve tvaru elips, odpovídaly oblastem zájmu v obrázcích a byly klíčové pro segmentační úlohu (Obrázek 5.2). Tyto předzpracované datové sady byly poté použity pro trénink, validaci a testování modelu, čímž byl optimalizován proces analýzy a zajištěna přesnost modelu při práci s různorodými daty.



Obrázek 5.2 Snímek prsního implantátu s intrakapsulární rupturou (vlevo). Oblast zájmu – znak intrakapsulární ruptury (uprostřed). Maska generovaná ve tvaru elipsy (vpravo).

5.2 Architektura neuronových sítí

Architektury neuronových sítí obecně zahrnují vrstvy neuronů naskládané na sebe, které zpracovávají data postupně, přičemž každá vrstva se učí složitější reprezentace vstupních dat. Nejjednodušší architektury, jako je LeNet, používají konvoluční vrstvy pro extrakci příznaků a plně propojené vrstvy pro klasifikaci. Modernější architektury, jako jsou Inception, ResNet a Xception, zlepšují výkon zaváděním inovací, jako jsou reziduální spojení (Residual Connection), hloubkově oddělitelné konvoluce (Depthwise Separable Convolution) nebo Inception moduly, což umožňuje efektivnější učení a lepší výsledky na složitých úlohách, jako je rozpoznávání obrazu [59].

V klinické praxi je obtížné sehnat velký soubor dat a vzhledem k potřebě velkého množství dat pro vytvoření nové sítě, v disertační práci bylo využito tři předtrénovaných sítí. Sítě byly předtrénované na datové sadě ImageNet, která obsahuje více než 14 milionů anotovaných obrázků [70]. Konkrétně byly použity hluboké neuronové sítě ResNet-18, ResNet-50, Xception. Tyto sítě mají předem připravenou strukturu (příloha B), naučené prahy a váhy, a také předem definovanou velikost vstupních dat.

Resnet-18 a Resnet-50

Architektura neuronové sítě ResNet (Residual Network), kterou představili He et al., využívá reziduální bloky. Tyto bloky obsahují přeskoková spojení, která umožňují, aby informace z výstupu jedné vrstvy byly přeneseny přímo do další vrstvy (nebo ještě dále), čímž se obchází některé mezivrstvy. Tato metoda usnadňuje učení hlubokých sítí tím, že snižuje problém mizejícího gradientu a umožňuje efektivní přenos informací skrze síť.

Technika přeskokových spojení spolu s dávkovou normalizací zlepšuje stabilitu a rychlost trénování. Existuje několik variant ResNet, například ResNet-18 (18 vrstev) a ResNet-50 (50 vrstev). ResNet-50 využívá tzv. „bottleneck bloky“, které umožňují efektivní zpracování hlubších sítí. Tyto varianty poskytují flexibilitu při aplikaci na různé úlohy s odlišnými nároky na výkon a výpočetní složitost [66].

Xception

Architektura neuronové sítě Xception se skládá z 36 konvolučních vrstev, které tvoří základ pro extrakci příznaků z obrazu. Na tento základ navazuje vrstva logistické regrese, která zpracovává extrahované příznaky a provádí konečnou klasifikaci. Neuronová síť Xception byla navržena jako vylepšení architektury Inception, přičemž využívá hloubkově oddělitelnou konvoluci pro efektivnější filtrování a kombinování informací. Díky tomu Xception využívá parametry modelu efektivněji, což dokládá její lepší výkon na datových sadách ImageNet a datové sadě Google JFT s 350 miliony obrázků. Tato technika spolu s reziduálními spojeními (Residual connections) zajišťuje lepší učení modelu a zlepšuje tréninkový proces, což vede k lepším výsledkům při klasifikaci [72].

5.3 Trénování modelu

Trénování neuronové sítě je klíčovým krokem v procesu hlubokého učení, který ovlivňuje její schopnost generalizace a přesnost predikcí. Aby síť dosáhla co nejlepších výsledků, je nezbytné pečlivě optimalizovat její architekturu a hyperparametry. Mezi hlavní hyperparametry patří rychlost učení (Learning Rate), velikost dávky (Batch Size), počet epoch a volba optimalizačního algoritmu, jako je Adam (Adaptive Moment Estimation) nebo SGDM (Stochastic Gradient Descent with Momentum). Výběr vhodných parametrů je důležitý pro efektivní učení a může výrazně ovlivnit konvergenci a přesnost modelu [73].

5.3.1 Hyperparametry

Rychlost učení (Learning Rate)

Rychlost učení určuje, jak velké kroky dělá algoritmus při aktualizaci vah sítě během každé iterace trénování. Vyšší rychlost učení způsobuje, že se model učí rychleji, ale může přeskočit globální minimum ztrátové funkce a dosáhnout pouze jeho okolí. Nižší rychlost učení zvyšuje pravděpodobnost nalezení globálního minima ztrátové funkce. Jako kompromis však nižší rychlost učení vyžaduje více epoch, což znamená delší čas trénování a vyšší nároky na paměťové zdroje.

Velikost dávky (Batch Size)

Velikost dávky definuje počet trénovacích vzorků, které jsou použity pro výpočet gradientu a aktualizaci vah během jedné iterace. Malá velikost dávky může způsobit šum v aktualizaci gradientu, což může vést k lepší generalizaci modelu, ale také k delšímu trénování. Naopak velká velikost dávky může vést k rychlejší konvergenci, avšak také zvýšit riziko přetrénování.

Počet epoch

Počet epoch představuje, kolikrát je trénovací dataset předložen síti během tréninku. Každá epocha znamená, že model viděl všechny trénovací data jednou. Příliš mnoho epoch může vést k přetrénování, kdy model začne „přizpůsobovat“ specifika trénovacích dat a nebude dobře generalizovat na testovacích datech. Naopak příliš málo epoch může způsobit nedotrénování sítě, což znamená, že model nedostatečně zachytí vzory v datech.

Optimalizátor

Optimalizátor je zodpovědný za nastavení rychlosti učení a úpravu vah neuronů v neuronové síti tak, aby bylo dosaženo minima ztrátové funkce. Je klíčový pro dosažení co nejvyšší přesnosti nebo minimalizace ztráty. Existuje několik typů optimalizátorů, přičemž každý má odlišný přístup k hledání minima. Nejčastěji se používají

optimalizátory Adam a SGDM které se osvědčily jako spolehlivé a efektivní pro širokou škálu úloh [73].

Váhy tříd (Class Weight)

Při trénování modelu byly aplikovány váhy pro jednotlivé třídy, konkrétně pro pozadí (Background) a rupturu (Target Region). Tyto váhy byly nastaveny tak, aby model kladl větší důraz na detekci ruptur, které mohou být ve srovnání s pozadím v datasetu méně časté. Nastavení vah tak pomáhá řešit problém nevyváženosti dat a minimalizuje riziko, že model bude upřednostňovat početnější třídu pozadí.


Výše uvedené hyperparametry hrají zásadní roli při řízení toho, jakým způsobem se model učí z trénovacích dat a jak rychle konverguje k optimálnímu řešení. Optimalizace rychlosti učení a velikosti dávky (minibatch) má přímý vliv na přesnost, rychlost trénování a na schopnost modelu efektivně generalizovat na nová data. Úspěšný výběr těchto parametrů byl výsledkem několika experimentů s různými konfiguracemi modelů.

Bylo natrénováno několik modelů neuronových sítí za účelem nalezení nejvhodnějšího modelu pro automatickou detekci intrakapsulárních ruptur. Pro výběr nejrelevantnějšího modelu byl použit jako hlavní ukazatel výkonnosti parametr průměrné přesnosti ve snímcích na testovací sadě, který nejlépe reflektuje schopnost modelu generalizovat a úspěšně klasifikovat nové, dosud neviděné snímky

5.3.2 Augmentace

Vzhledem k omezenému počtu a nevyváženosti dat bylo klíčové využít techniky augmentace k rozšíření trénovacího datasetu a optimalizaci modelu pro dosažení co nejvyšší přesnosti při detekci intrakapsulárních ruptur. Augmentace dat slouží k rozšíření trénovacího datasetu a zahrnuje umělé generování nových trénovacích dat pomocí transformací, jako jsou rotace, posuny, převrácení nebo přidávání šumu. Tímto způsobem se zvyšuje rozmanitost trénovacích dat, což pomáhá modelu lépe generalizovat na nová, neviděná data.

Pro zvýšení variability a robustnosti tréninku byly použity rotace obrazů a posuny v osách X a Y, které zajistily, že model bude odolný vůči malým změnám ve vstupních obrazech. Kromě toho byl u některých modelů aplikován filtr pro detekci hran, který zvýrazňoval hrany a obrysy objektů pomocí nastavené prahové hodnoty a zesílení. Tento filtr potlačil méně výrazné části obrazu, čímž zvýraznil struktury důležité pro segmentaci a detekci (Obrázek 5.3).



Obrázek 5.3 Originální snímek prsního implantátu bez použití filtru (vlevo). Snímek prsního implantátu s použitím hranového filtru (vpravo).

5.4 Vyhodnocení modelu

Statistické vyhodnocení modelu neuronové sítě je klíčovým krokem při posuzování kvality a spolehlivosti predikcí, které model generuje. Cílem je zjistit, jak přesně model dokáže předpovídat na základě trénovacích a validačních dat a jak dobře se jeho predikce přenášejí na testovací, tedy na neznámá data.

Ve strojovém učení se pro statistické vyhodnocení používá binární matice záměn (Confusion Matrix). V potaz jsou brány dvě třídy: Ruptury a pozadí (Obrázek 5.4).

		Předpokládaný stav	
		Ruptury	Pozadí
Skutečný stav	Ruptury	TP	FN
	Pozadí	FP	TN

Obrázek 5.4 Matice záměn (Confusion Matrix) [74]

Data, se kterými je potřeba pracovat při vyhodnocení, lze rozdělit do čtyř skupin:

- TP (True Positive) – počet pixelů, které jsou ve skutečnosti pozitivní a byli zařazeni mezi pozitivní.
- FP (False Positive) – počet pixelů, které jsou ve skutečnosti negativní, přičemž byli zařazeni mezi pozitivní.
- TN (True Negative) – počet pixelů, které jsou ve skutečnosti negativní, přičemž byli zařazeni mezi negativní.
- FN (False Negative) – počet pixelů, které jsou ve skutečnosti pozitivní, přičemž byli zařazeni mezi negativní [74].

Vyhodnocení klasifikace pixelů ve snímku

M	– počet snímků v datasetu (count of frames)	$M \in \mathbb{Z}$
P_i	– počet pozitivních v snímku (positive per frame)	$i \in \{1, 2, \dots, M\}$
N_i	– počet negativních v snímku (negative per frame)	$i \in \{1, 2, \dots, M\}$
TP_i	– počet pravdivě pozitivních v snímku (true positive per frame)	$i \in \{1, 2, \dots, M\}$
TN_i	– počet pravdivě negativních v snímku (true negative per frame)	$i \in \{1, 2, \dots, M\}$

Vyhodnocení klasifikace pixelů v datasetu

$$\begin{aligned} P &= \sum_{i=1}^M P_i & P & \text{– počet pozitivních v datasetu (positive per dataset)} \\ N &= \sum_{i=1}^M N_i & N & \text{– počet negativních v datasetu (negative per dataset)} \\ TP &= \sum_{i=1}^M TP_i & TP & \text{– počet pravdivě pozitivních v datasetu (true positive per dataset)} \\ TN &= \sum_{i=1}^M TN_i & TN & \text{– počet pravdivě negativních v datasetu (positive per dataset)} \end{aligned}$$

Přesnost (Accuracy)

Přesnost je metrika používaná v klasifikaci obrazových dat a dalších klasifikačních úlohách, která vyjadřuje podíl správně klasifikovaných pixelů (pozitivních i negativních) vzhledem k celkovému počtu pixelů v celém datasetu.

Matematicky je přesnost vyjádřena jako:

$$ACC = \frac{TP + TN}{P + N} \quad (5.1)$$

Přesnost se pohybuje v rozmezí 0–1, kde 1 znamená, že všechny pixely byly správně klasifikovány.

Průměrná přesnost snímku (Mean frame accuracy)

Metrika průměrné přesnosti snímku vyhodnocuje klasifikaci pixelů ve snímku.

Matematicky vyjádřena jako:

$$ACC_{mf} = \frac{1}{M} \cdot \sum_{i=1}^M \frac{W_P \cdot TP_i + W_N \cdot TN_i}{W_P \cdot P_i + W_N \cdot N_i} \quad (5.2)$$

$$W_P = \frac{P}{P + N} \quad \text{váha pozitivních v datasetu (weight of positive in dataset)}$$

$$W_N = \frac{N}{P + N} \quad \text{váha negativních v datasetu (weight of negative in dataset)}$$

Pozitivní prediktivní hodnota (Precision)

Parametr precision udává podíl správně předpovězených pozitivních vzorků ze všech vzorků, které byly klasifikovány jako pozitivní. Jinými slovy, vyjadřuje, jak dobře klasifikátor předpovídá pozitivní třídu bez zbytečných falešně pozitivních předpovědí. Precision se zaměřuje na to, jak spolehlivě model předpovídá pozitivní případy z těch, které klasifikoval jako pozitivní. Je obzvláště důležitá v případech, kdy jsou chyby typu False Positive kritické, například při lékařské diagnostice.

Matematicky je přesnost vyjádřena jako:

$$Precision = \frac{TP}{TP + FP} \quad (5.3)$$

Senzitivita (Recall)

Senzitivita (TPR) nebo také recall označuje schopnost modelu správně identifikovat pozitivní případy, tj. v lékařské diagnostice například rozpoznat přítomnost určité patologie. Senzitivita se vypočítává jako pravděpodobnost, že skutečně pozitivní vzorky (např. pacienti s přítomnou patologií) budou správně klasifikovány jako pozitivní. Vysoká senzitivita znamená, že model identifikoval většinu pozitivních případů, ale může to být na úkor vyššího počtu falešně pozitivních výsledků (nižší precision). Recall je klíčovou metrikou v oblastech, kde je důležité minimalizovat počet chybějících pozitivních případů.

Matematicky je senzitivita vyjádřena jako:

$$\text{Senzitivita} = \frac{TP}{TP + FN} \quad (5.4)$$

Specificita

Specificita (TNR) označuje schopnost testu správně identifikovat případy bez patologií, tedy negativní případy. Vyjadřuje pravděpodobnost, že test správně klasifikuje vzorek jako negativní, pokud ve skutečnosti neobsahuje patologii. Jinými slovy, specificita měří, jak dobře test nebo model dokáže rozeznat skutečně negativní případy a zabránit falešně pozitivním výsledkům.

Matematicky je specificita vyjádřena jako:

$$\text{Specificita} = \frac{TN}{TN + FP} \quad (5.5)$$

F₁ skóre

F₁ skóre je metrika používaná v klasifikaci, která představuje harmonický průměr mezi precision a recall. Tato metrika je obzvláště užitečná v případech, kdy potřebujeme najít rovnováhu mezi přesností modelu a jeho schopností správně identifikovat všechny pozitivní případy. F₁ skóre je vhodné tam, kde jsou důležité jak falešně pozitivní, tak falešně negativní výsledky.

Matematicky je F₁ skóre vyjádřeno jako:

$$F1\ score = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (5.6)$$

F₁ skóre je užitečné v případech, kdy jsou třídy v datech nevyvážené, nebo když je třeba minimalizovat jak falešně pozitivní, tak falešně negativní předpovědi. Maximální hodnota F₁ skóre je 1, což představuje rovnováhu mezi přesností a citlivostí. Naopak hodnota 0 značí velmi slabý výkon modelu [74–76].

6 Výsledky

V rámci disertační práce bylo natrénováno několik modelů neuronových sítí pro detekci intrakapsulárních ruptur prsních implantátů. Trénování modelů bylo realizováno na GPU Nvidia GeForce RTX 4070, přičemž byly zvoleny tři architektury neuronových sítí: ResNet-18, ResNet-50 a Xception. Dále byla použita kombinace těchto předtrénovaných modelů, cílem bylo zvýšení přesnosti detekce. V rámci nastavení hyperparametrů byly použity optimalizační algoritmy Adam a SGDM, které slouží k minimalizaci ztrátové funkce modelu a tím i k dosažení co nejvyšší přesnosti.

Počáteční rychlost učení byla nastavena na hodnotu $1e^{-3}$, rychlost musí být taková, aby nedošlo k uváznutí v lokálním minimu a nalezení optima bylo rychlé. Trénink probíhal po dobu 10 až 50 epoch s minibatch o velikosti 8, 16 a 32. To znamená, že při každém kroku učení byly modelu předávány malé podmnožiny trénovacích dat (minibatch), což zlepšuje stabilitu učení a snižuje riziko přeučení. Pro zvýšení variability dat byly u jednotlivých modelů použity augmentační techniky jako je rotace a translace v osách X, Y a u některých modelů byl zvolen hranový filtr pro detekci hran.

6.1 ResNet-18

Celkem bylo natrénováno 33 modelů neuronové sítě ResNet-18 s různými nastaveními hyperparametrů (Tabulka 6.1) a použitím augmentačních technik (Tabulka 6.2). Výběr modelu byl proveden na základě průměrné přesnosti ve snímku, nejvyšší přesnosti dosáhl Model 2Xa. Neuronová síť byla trénována pomocí optimalizačního algoritmu SGDM po dobu 15 epoch s rychlostí učení $1e^{-3}$ a velikostí mini-batch 16.

Vzhledem k silné nevyváženosti tříd (pozadí a ruptura) byly použity váhy tříd (1;50), čímž byla upřednostněna třída ruptury. Průběh trénování je znázorněn na obrázku (Obrázek 6.1). Průměrná přesnost ve snímku byla 94,25 %, což naznačuje, že model dokáže efektivně generalizovat na testovacích datech. Dále byly vyhodnoceny parametry: ACC = 94,63 %, TPR = 94,80 %, TNR = 86,97 % a F1 = 97,18 % (Tabulka 6.3).

Tabulka 6.1 Model 2Xa: Nastavené hyperparametry


Parametr	Hodnota
Rychlost učení	$1e^{-3}$
Velikost mini-batch	32
Počet epoch	10
Optimalizační algoritmus	Adam
Váhy tříd	1;50

Tabulka 6.2 Model 2Xa: Použití augmentačních technik

Parametr	Hodnota
Augmenter rot	$\pm 180^\circ$
Augmenter X	± 10 pixelů
Augmenter Y	± 10 pixelů

Tabulka 6.3 Model 2Xa: Výsledky model

Parametr	Hodnota
ACC	0,94626
ACC _{mf}	0,94247
TPR	0,94801
TNR	0,86971
F ₁ skóre	0,97182



Obrázek 6.1 Proces trénování neuronové sítě Resnet-18. Na horním grafu lze vidět závislost přesnosti na počtu iterací a na dolním grafu je znázorněna změna ztráty na počet iterací.

6.2 ResNet-50

Celkem bylo natrénováno 14 modelů neuronové sítě ResNet-50 s různými nastaveními hyperparametrů (Tabulka 6.4) a použitím augmentačních technik (Tabulka 6.5). U modelu byl použit hranový filtr. Výběr modelu byl proveden na základě průměrné přesnosti ve snímku, nejvyšší přesnosti dosáhl Model 5. Neuronová síť byla trénována pomocí optimalizačního algoritmu SGDM po dobu 10 epoch s rychlostí učení $1e^{-3}$ a velikostí mini-batch 16.

Vzhledem k silné nevyváženosti tříd (pozadí a ruptura) byly použity váhy tříd (1;25), čímž byla upřednostněna třída ruptury. Průběh trénování je znázorněn na obrázku (Obrázek 6.2). Průměrná přesnost ve snímku byla 93,69 %, což naznačuje, že model dokáže efektivně generalizovat na testovacích datech. Dále byly vyhodnoceny následující parametry: ACC = 94,07 %, TPR = 94,25 %, TNR = 86,26 % a F_1 skóre = 96,88 % (Tabulka 6.6).

Tabulka 6.4 Model 5: Nastavené hyperparametry


Parametr	Hodnota
Rychlost učení	$1e^{-3}$
Velikost mini-batch	16
Počet epoch	10
Optimalizační algoritmus	SGDM
Váhy tříd	1;25

Tabulka 6.5 Model 5: Použité augmentační techniky

Parametr	Hodnota
Augmenter rot	$\pm 180^\circ$
Augmenter X	± 50 pixelů
Augmenter Y	± 50 pixelů

Tabulka 6.6 Model 5: Výsledky

Parametr	Hodnota
ACC	0,94074
ACC _{mf}	0,93692
TPR	0,94253
TNR	0,86268
F_1 skóre	0,96884



Obrázek 6.2 Proces trénování neuronové sítě Resnet-50. Na horním grafu lze vidět závislost přesnosti na počtu iterací a na dolním grafu je znázorněna změna ztráty na počet iterací.

6.3 Xception

Celkem bylo natrénováno 13 modelů neuronové sítě Xception s různými nastaveními hyperparametrů (Tabulka 6.7) a použitím augmentačních technik (Tabulka 6.8). Výběr modelu byl proveden na základě průměrné přesnosti ve snímku, nejvyšší přesnosti dosáhl Model 38Xc. Neuronová síť byla trénována pomocí optimalizačního algoritmu Adam po dobu 50 epoch s rychlostí učení $1e^{-3}$ a velikostí mini-batch 32.

Vzhledem k silné nevyváženosti tříd (pozadí a ruptura) byly použity váhy tříd (1;50), čímž byla upřednostněna třída ruptury. Průběh trénování je znázorněn na obrázku Obrázek 6.3). Průměrná přesnost ve snímku byla 94,58 %, což naznačuje, že model dokáže efektivně generalizovat na testovacích datech. Dále byly hodnoceny parametry ACC = 95,25 %, TPR = 95,45 %, TNR = 86,77 % a F_1 skóre = 97,52 % (Tabulka 6.9).

Tabulka 6.7 Model 38Xc: Nastavené hyperparametry


Parametr	Hodnota
Rychlost učení	$1e^{-3}$
Velikost mini-batch	32
Počet epoch	50
Optimalizační algoritmus	Adam
Váhy tříd	1;50

Tabulka 6.8 Model 38Xc: Použité augmentační techniky

Parametr	Hodnota
Augmenter rot	$\pm 180^\circ$
Augmenter X	± 10
Augmenter Y	± 10

Tabulka 6.9 Model 38Xc: Výsledky

Parametr	Hodnota
ACC	0,95254
ACC _{mf}	0,94579
TPR	0,95448
TNR	0,86774
F_1 skóre	0,97520



Obrázek 6.3 Proces trénování neuronové sítě Xception. Na horním grafu lze vidět závislost přesnosti na počtu iterací a na dolním grafu je znázorněna změna ztráty na počet iterací

6.4 Kombinace modelů

V rámci zvýšení přesnosti predikcí byla využita kombinace modelů (Ensemble Learning), která zahrnovala různé neuronové sítě. Cílem bylo zkombinovat jejich silné stránky a minimalizovat chyby jednotlivých modelů. Výsledky ukázaly, že kombinace modelů skutečně vedla ke zlepšení sledovaného parametru, tedy průměrné přesnosti pixelu ve snímku. Nejvyšší hodnoty ACC_{mf} (0,95) dosáhl Kombinovaný model 3 (Tabulka 6.10), který kombinuje modely: Model5, Model38Xc a Model2Xa (Tabulka 6.11).

I když rozdíly mezi jednotlivými modely nejsou výrazné, kombinace několika modelů přispěla k celkovému zlepšení kvality predikcí, jak je patrné z dosažených hodnot uvedených v tabulce. Tyto výsledky potvrzují, že použití ensemble techniky má pozitivní vliv na výkon modelu, přičemž nejvyšší ACC_{mf} bylo dosaženo díky kombinaci více modelů s různou neuronovou sítí a nastavením hyperparametrů.

Tabulka 6.10 Výsledky kombinovaných modelů

Model	ACC	ACC_{mf}	TPR	TNR	F ₁ skóre
1	0,94292	0,95217	0,95865	0,87977	0,97751
2	0,94211	0,94178	0,96075	0,83872	0,97813
3	0,94244	0,95367	0,95656	0,88886	0,97652
4	0,94111	0,94817	0,95473	0,87601	0,97542
5	0,93789	0,94938	0,95417	0,88099	0,97518
6	0,93710	0,95096	0,95355	0,88654	0,97492
7	0,94255	0,94882	0,95709	0,87294	0,97662

Tabulka 6.11 Výsledky vybraných modelů


Model	ACC	ACC_{mf}	TPR	TNR	F ₁ skóre
Model 2Xa	0,94626	0,94247	0,94801	0,86971	0,97182
Model 5	0,94074	0,93692	0,94253	0,86268	0,96884
Model 38Xc	0,95254	0,94579	0,95448	0,86774	0,97520
Model 3	0,94244	0,95367	0,95656	0,88886	0,97652

6.5 Návrh diagnostického postupu

V ČR neexistuje jednotný autoritami schválený postup pro vyšetření žen s prsním implantátem. Navržený diagnostický postup pro ženy s prsním implantátem je klíčové pro včasnou detekci případných komplikací, jako je ruptura implantátu. Efektivní postup minimalizuje rizika a zátěž pro pacientky, umožňuje včasnou intervenci a snižuje pravděpodobnost dlouhodobých komplikací. Navržený postup vychází ze zahraničních odborných společností (Obrázek 6.4).

Navržený postup se zaměřuje na dvě skupiny pacientek:

1. Asymptomatické pacientky.
2. Pacientky s příznaky ruptury či podezřením na ruptura v důsledku mechanického poškození.



Obrázek 6.4 Návrh diagnostického postupu žen s prsním implantátem

7 Diskuze

Práce je zaměřena na detekci intrakapsulárních ruptur prsních implantátů pomocí předtrénovaných neuronových sítí na obrazových datech z MRI. Cílem výzkumu bylo navrhnout algoritmus pro poloautomatickou detekci intrakapsulárních ruptur, který může sloužit jako podpora pro rozhodování lékaře a přispět k přesnější diagnostice.

Mezi relevantními studiemi v problematice zaměřené na detekci ruptur jsou studie od autorů Salchenberg (1997) [57] a Venta (1998) [58]. Studie jsou zaměřené na využití neuronových sítí v oblasti UZ, což podtrhuje inovativnost přístupu zaměřeného na MRI. Další studie v souvislosti použití neuronových sítí u prsních implantátů jsou zaměřeny na BI-ALCL, volbu implantátu atd., což nebylo předmětem této práce.

V rámci experimentů bylo natrénováno několik různých modelů pro každou ze tří zvolených architektur neuronových sítí (NN): Xception, ResNet-18 a ResNet-50. Z každé architektury byl následně vybrán ten model, který dosahoval nejlepších výsledků.

Existuje několik parametrů, dle kterých lze úspěšnost modelu hodnotit. V této práci bylo pro hodnocení úspěšnosti či přesnosti modelu zvolen parametr průměrné přesnosti ve snímku (ACC_{mf}) a to ze dvou důvodů. Jedním z důvodů je vyrovnaná úspěšnost detekce na jednotlivých snímcích a dalším důvodem je, že tento parametr oproti parametru přesnosti v celém datasetu (ACC) zohledňoval hodnotu specificity. Senzitivita a specificita jsou v medicíně důležitými metrikami při stanovení diagnózy.

Model NN Xception (Model 38Xc) dosáhl nejvyšší hodnoty ACC_{mf} na trénovacích, validačních a testovacích datech. Velikost vstupních obrázků byla 299 x 299. Delší trénink (50 epoch) a větší velikost minibatch (32) modelu umožnily detailní naučení rysů relevantních pro detekci. Optimalizátor Adam napomohl rychlé konvergenci k vysoké přesnosti, zatímco augmentace dat (rotace $\pm 180^\circ$ a translace ± 10 pixelů) zvýšila schopnost modelu generalizovat. Celkově tedy model NN Xception vykazoval nejlepší schopnost klasifikace.

Model NN ResNet-18 (Model 2Xa) dosáhl velmi podobné přesnosti jako model NN Xception, a to i přes nižší počet epoch (15) a menší minibatch (16). Tento model pracoval s většími obrázky (500 x 500), což přineslo výhodu při rozpoznávání detailnějších obrazových rysů. Model NN ResNet-18, jednodušší než NN ResNet-50, nabídl dobrý kompromis mezi tréninkovou rychlostí a přesností. Použitá augmentace byla obdobná jako u modelu NN Xception, zahrnovala rotaci $\pm 180^\circ$, translaci ± 10 pixelů. Hodnota ACC_{mf} na testovacích datech byla mírně nižší než u modelu NN Xception, ale stále velmi vysoká.

Model NN ResNet-50 (Model 5) vykazoval nejnižší ACC_{mf} na testovacích datech, pravděpodobně kvůli menšímu počtu epoch (10). Tento model je architektonicky

složitější, což klade vyšší nároky na trénink a počítačový výkon. Použitý optimalizátor SGDM vyžaduje více epoch pro dosažení optimálních výsledků, což se zde projevilo na nižší přesnosti. Širší rozsah translace (± 50 pixelů) v augmentaci a hranový filtr sice pomohly modelu lépe se vypořádat s variacemi v datech, avšak širší translace mohla způsobit ztrátu detailů, což vedlo k horší klasifikaci.

Kromě použití jednotlivých modelů byla použita metoda Ensemble Learning, která kombinuje různé modely za účelem zvýšení celkové přesnosti detekce ruptur. Metoda Ensemble Learning byla navržen tak, aby kombinovala silné stránky různých modelů a eliminovala jejich slabiny. Nejvyšší ACC_{mf} na testovacích datech (0.95367) dosáhl Kombinovaný model 3, který zahrnuje Model 5, Model 38Xc a Model 2Xa. I když rozdíly mezi jednotlivými kombinovanými modely nejsou výrazné, metoda Ensemble Learning přispěla ke zvýšení kvality predikcí tím, že integrovala několik perspektiv na analýzu MRI snímků. Senzitivita dosahovala 95,66 %, specifická 88,89 %. Parametr senzitivity je vyšší, než uvádí Autor Song ve své meta-analýze, která je zaměřena na diagnostickou přesnost MRI pro detekci ruptur. Kdežto parametr specifity je o něco vyšší v rámci analyzovaných studií. Výsledky meta-analýzy udávají senzitivitu 87 %, specifitu 89,8 %. Kombinace hodnocení lékařem a neuronové sítě by mohla přispět k vyšší diagnostické přesnosti

V rámci této práce lze výsledky kombinace modelů srovnat se studií Rouzi a kol. (2023) [78], která se zaměřuje na detekci karcinomu prsu pomocí kombinace několika neuronových sítí, včetně modelů jako EfficientNet, Xception a ResNet50. Tato kombinace modelů vedla k výraznému zvýšení přesnosti, a to díky využití metody konsenzuální adaptivní váhy, která umožnila dynamické přizpůsobení vah mezi jednotlivými sítěmi. Podobně jako v této práci se ukázalo, že kombinace různých modelů zlepšuje schopnost generalizace a přináší vyšší diagnostickou přesnost, což potvrzuje užitečnost Ensemble Learningu i pro detekci intrakapsulárních ruptur prsních implantátů.

Další relevantní studie, kterou lze zmínit, je práce Ragaba a kol. (2022) [79], která se zabývala klasifikací karcinomu prsu na základě ultrazvukových snímků. Autoři této studie použili kombinaci tří hlubokých neuronových sítí (VGG-16, VGG-19 a SqueezeNet) pro extrakci obrazových rysů, následně aplikovali optimalizovaný model strojového učení pro klasifikaci nádorů. Výsledky této studie ukazují, že kombinace modelů vedla k významnému zlepšení přesnosti klasifikace a zdůrazňuje, jak Ensemble metoda zvyšuje schopnost detekovat složité obrazové rysy, které by jednotlivé modely mohly přehlédnout. To opět podporuje závěry této práce, že Ensemble learning je vhodný přístup ke zlepšení přesnosti detekce intrakapsulárních ruptur.

Tento kombinovaný přístup ukazuje, že každý model může nabídnout unikátní pohled na data, přičemž jejich kombinací lze dosáhnout vyšší diagnostické přesnosti. Ensemble metoda by mohla být do budoucna rozšířena i o další typy modelů nebo

doplněna o optimalizace na základě konkrétních klinických potřeb, což by přispělo k dalšímu zvýšení diagnostické přesnosti a využitelnosti modelů v klinickém prostředí.

Dílčím cílem této disertační práce bylo analyzovat použití zobrazovacích metod při vyšetření prsních implantátů, se zaměřením na jejich efektivitu. Na základě literární rešerše a analýzy dostupných studií bylo zjištěno, že samotné klinické vyšetření pacientek s prsními implantáty často není dostačující, a proto je nezbytné zahrnout také zobrazovací metody.

Dle literatury je UZ metodou první volby, což je dáno její snadnou dostupností jak po finanční, tak po časové stránce. Nevýhodou této metody však je, že provedení interpretace snímků do velké míry závisí na subjektivním hodnocení a zkušenostech lékaře [38]. Subjektivní hodnocení může vést k přehlédnutí některých patologií, například intrakapsulární ruptury, kterou nemusí být vždy možné odhalit včas. Alternativou s vyšší spolehlivostí v diagnostice ruptur je MRI.

Metoda MRI nabízí přesnější diagnostiku a je považována za spolehlivější metodu při detekci intrakapsulární ruptury. Při diagnostice může dojít k záměně ruptur s radiálními záhyby, což opět vyžaduje zkušenost a odborné posouzení lékaře [80]. Mezi nevýhody MRI patří horší časová i finanční dostupnost, neboť čekací doby na vyšetření bývají delší a náklady na provedení jsou vyšší než u UZ.

Přesná a včasná diagnostika ruptur prsních implantátů je zásadní nejen pro zdravotní stav pacientky, ale také z ekonomického hlediska. Nepřesná diagnostika může vést k neopodstatněným chirurgickým zákrokům, tedy k odstranění implantátu, což představuje zátěž zdravotní i finanční.

Kompromisním řešením by mohla být LF-MRI, která sice nabízí nižší kvalitu obrazu (nižší SNR), avšak dle dostupných studií je i tak dostatečná pro identifikaci ruptur. Studie autorů Frankela a kol. [45] naznačuje, že LF-MRI je vhodná nejen pro detekci ruptur, ale také pro rozlišení mezi deformitami implantátu a radiálními záhyby. Výhodou LF-MRI jsou nižší pořizovací a provozní náklady.

Vzhledem k absenci standardizovaného diagnostického postupu v ČR pro vyšetření žen s prsními implantáty, byl v této práci navržen diagnostický postup. Neexistence jednotných pokynů při podezření na rupturu implantátu může vést k nejednotnému přístupu diagnostiky. Tento problém zmiňuje i studie autora Zingaretti [81], která zdůrazňuje, že absence standardizovaného postupu v diagnostice implantátů je jedním z faktorů přispívajících k zbytečným intervencím.

Navrhovaný postup je postaven na dvoustupňovém systému, který zahrnuje:

- Screening, zaměřený na ženy, které mají 5 let po implantaci a následně by vyšetření podstupovaly 1x za 2 roky:
 - UZ.
 - Při podezření na rupturu na základě UZ, by pacientka měla podstoupit MRI.
 - V případě ruptury, pacientka podstoupí vyjmutí implantátu.
- Vyšetření v případě podezření na rupturu, tzn. pacientka má příznaky ruptury, či prodělala mechanické poškození:
 - MRI.
 - V případě ruptury, pacientka podstoupí vyjmutí implantátu.

Navržený postup vychází z doporučení odborných společností ve světě a přináší možnost optimalizace zdravotnických nákladů a snížení rizika nadbytečných chirurgických zásahů, přičemž zachovává vysokou míru bezpečnosti a přesnosti v diagnostice.

Limitace disertační práce

Jedním z hlavních omezení této práce je relativně malá velikost a variabilita datové sady, což vedlo k nutnosti využití augmentačních technik. Ruptury mají různý charakter, což v datasetu způsobilo různé zastoupení. Pro dosažení kvalitních výsledků je ideální, aby trénovací dataset obsahoval velký počet reprezentativních snímků [82]. Aby byla zajištěna variabilita a rozšířena tréninková data, byly použity augmentační techniky, což zahrnovalo umělé zvětšení datové sady na základě existujících dat. Takové kroky jsou běžné, jak potvrzuje systematický přehled studií zaměřený na použití augmentačních technik [83]. Ačkoli augmentace (rotace a translace) pomohla zvýšit variabilitu dat, modely mohou mít i tak omezenou schopnost generalizace na všechna klinická data.

Dalším omezením této studie je snížená kvalita některých snímků způsobená přítomností RFID (Radio Frequency Identification) čipů na zadní stěně implantátů [84]. Tyto čipy jsou v Evropě i USA povinné, protože poskytují jedinečnou identifikaci implantátu, včetně sériového čísla, data výroby, expirace a čísla šarže [84, 85]. Přítomnost magnetického kovu v RFID čipech však v silném magnetickém poli MRI přístrojů způsobuje artefakty, které snižují kvalitu obrazu. Použití LF-MRI by mohlo tento problém částečně eliminovat, neboť pracuje s nižším magnetickým polem, a tím snižuje pravděpodobnost vzniku nežádoucích artefaktů.

Úskalím je také to, že navržený algoritmus poloautomatické detekce byl zaměřen pouze na intrakapsulární ruptury, a to vzhledem k malé dostupnosti dat. Pokud by bylo k dispozici větší množství dat a variabilita z hlediska patologií, navržený algoritmus by mohl mít schopnost rozpoznat různé patologie implantátů.

8 Závěr

Cílem disertační práce bylo navrhnout algoritmus pro poloautomatickou detekci časných intrakapsulárních ruptur na základě hodnocení integrity silikonových prsních implantátů na MRI. Dílčím cílem bylo analyzovat diagnostické metody pro hodnocení prsních implantátů. Byla provedena literární rešerše těchto metod, přičemž jejich efektivita byla porovnána z hlediska senzitivity a specifity.

Výsledky literární rešerše ukázaly, že diagnostickou metodou první volby je UZ, díky její finanční dostupnosti. Senzitivita se pohybovala v rozmezí 30–98 % a specifita v rozmezí 24–90 %. Další analyzovanou metodou byla MG, která má v diagnostice intrakapsulárních ruptur omezené využití a je vhodná zejména pro detekci extrakapsulárních ruptur. Zlatým standardem v diagnostice je MRI, která je doporučována světovými odbornými společnostmi a disponuje nejvyšší senzitivitou 72–90 % a specifitou 78–99,5 %.

Součástí práce bylo také charakterizovat a popsat ruptury na snímcích MRI. Následně byl navržen algoritmus pro poloautomatickou detekci ruptur prsních implantátů. K dispozici byl dataset 30 pacientek (1428 řezů), který byl rozdělen na trénovací, validační a testovací množinu. Vzhledem k omezenému množství dat byl dataset uměle rozšířen pomocí augmentačních technik. Algoritmus byl vytvořen v prostředí MATLAB s použitím předtrénovaných neuronových sítí. Z natrénovaných modelů dosahovaly nejvyšší přesnosti modely Model 2Xa, Model 5, Model 38Xc. Pro zvýšení přesnosti byla použita metoda Ensemble Learning, kde byly kombinovány již zmíněné modely, které dosahovaly nejvyšší přesnosti.

Funkčnost algoritmu byla statisticky vyhodnocena. Průměrná přesnost detekce ruptur ve snímku dosahuje 95,34 % (Kombinovaný model 3). V 95,66 % případech algoritmus správně detekoval rupturu a v 88,89 % správně identifikoval případy bez ruptury. Navržený algoritmus by tak mohl podpořit diagnostiku inktrakapsulárních ruptur, které jsou často bezpříznakové. Mohl by sloužit jako druhý názor pro lékaře, čímž by došlo ke snížení subjektivního vlivu a zároveň k úspoře času.

Závěrem práce byl navržen ucelený postup pro diagnostiku pacientek s prsními implantáty, který v ČR doposud chybí.

Seznam použité literatury

- [1] “Plastic Surgery Statistics,” American Society of Plastic Surgeons. Accessed: Oct. 24, 2024. [Online]. Available: <https://www.plasticsurgery.org/news/plastic-surgery-statistics>
- [2] F. Goldammer, V. Pinsolle, C. Dissaux, and P. Péliissier, “Accuracy of mammography, sonography and magnetic resonance imaging for detecting silicone breast implant ruptures: A retrospective observational study of 367 cases,” *Annales de Chirurgie Plastique Esthétique*, vol. 66, no. 1, pp. 25–41, Feb. 2021, doi: 10.1016/j.anplas.2020.09.001.
- [3] T. Wong *et al.*, “Magnetic resonance imaging of breast augmentation: a pictorial review,” *Insights Imaging*, vol. 7, no. 3, pp. 399–410, Jun. 2016, doi: 10.1007/s13244-016-0482-9.
- [4] A. Maisel Lotan, M. Retchkiman, I. Tuchman, R. Binenboym, and Y. Gronovich, “Analysis of 109 Consecutive Explanted Breast Implants: Correlation Between Suspected Implant Rupture and Surgical Findings,” *Aesth Plast Surg*, vol. 40, no. 5, pp. 739–744, Oct. 2016, doi: 10.1007/s00266-016-0689-7.
- [5] N. Samreen *et al.*, “Imaging findings of mammary and systemic silicone deposition secondary to breast implants,” *British Journal of Radiology*, vol. 91, no. 1089, p. 20180098, Sep. 2018, doi: 10.1259/bjr.20180098.
- [6] S. L. Brown, M. S. Middleton, W. A. Berg, M. S. Soo, and G. Pennello, “Prevalence of rupture of silicone gel breast implants revealed on MR imaging in a population of women in Birmingham, Alabama,” *AJR Am J Roentgenol*, vol. 175, no. 4, pp. 1057–1064, Oct. 2000, doi: 10.2214/ajr.175.4.1751057.
- [7] C. for D. and R. Health, “Breast Implants - Certain Labeling Recommendations to Improve Patient Communication.” Accessed: Jun. 04, 2024. [Online]. Available: <https://www.fda.gov/regulatory-information/search-fda-guidance-documents/breast-implants-certain-labeling-recommendations-improve-patient-communication>
- [8] K. C. Chung, S. Malay, M. J. Shauver, and H. M. Kim, “Economic Analysis of Screening Strategies for Rupture of Silicone Gel Breast Implants,” *Plast Reconstr Surg*, vol. 130, no. 1, pp. 225–237, Jul. 2012, doi: 10.1097/PRS.0b013e318254b43b.
- [9] R. Čihák, *Anatomie 3*, 3. Praha: Grada, 2016.
- [10] A. P. Surgery, “Should implants go in front or behind the muscle?,” AI Plastic Surgery. Accessed: Aug. 29, 2024. [Online]. Available:

<https://www.aiplasticsurgery.com/learn/should-implants-go-in-front-or-behind-the-muscle/>

[11] S. Frankel *et al.*, “MRI Findings in Subjects with Breast Implants,” *Plastic and Reconstructive Surgery*, vol. 96, no. 4, p. 852, Sep. 1995.

[12] P. Brychta and J. Stanek, *Estetická plastická chirurgie a korektivní dermatologie*, 1. Praha: Grada, 2014.

[13] D. M. Coombs, R. Grover, A. Prassinos, and R. Gurunluoglu, “Breast augmentation surgery: Clinical considerations,” *CCJM*, vol. 86, no. 2, pp. 111–122, Feb. 2019, doi: 10.3949/ccjm.86a.18017.

[14] L. Dražan and J. Měšťák, *Rekonstrukce prsu po mastektomii*, 1. Grada, 2006.

[15] “Breast implants: the good, the bad and the ugly. Can nanotechnology improve implants? - Puskas - 2012 - WIREs Nanomedicine and Nanobiotechnology - Wiley Online Library.” Accessed: Jun. 06, 2024. [Online]. Available: <https://wires.onlinelibrary.wiley.com/doi/10.1002/wnan.164>

[16] S. Azahaf, K. A. Spit, C. J. M. de Blok, P. Bult, and P. W. B. Nanayakkara, “Silicone Migration from Intact Saline Breast Implants,” *Plast Reconstr Surg Glob Open*, vol. 12, no. 2, p. e5608, Feb. 2024, doi: 10.1097/GOX.0000000000005608.

[17] A. U. Daniels, “Silicone breast implant materials,” *Swiss Medical Weekly*, vol. 142, no. 2930, Art. no. 2930, Jul. 2012, doi: 10.4414/smw.2012.13614.

[18] J. W. Cohen Tervaert, M. J. Colaris, and R. R. van der Hulst, “Silicone breast implants and autoimmune rheumatic diseases: myth or reality,” *Current Opinion in Rheumatology*, vol. 29, no. 4, p. 348, Jul. 2017, doi: 10.1097/BOR.0000000000000391.

[19] D. H. Meshkin, J. M. Firriolo, N. S. Karp, and A. A. Salibian, “Management of complications following implant-based breast reconstruction: a narrative review,” *Ann Transl Med*, vol. 11, no. 12, p. 416, Dec. 2023, doi: 10.21037/atm-23-1384.

[20] A. Campanale, R. Boldrini, and M. Marletta, “22 Cases of Breast Implant–Associated ALCL: Awareness and Outcome Tracking from the Italian Ministry of Health,” *Plastic and Reconstructive Surgery*, vol. 141, no. 1, p. 11e, Jan. 2018, doi: 10.1097/PRS.0000000000003916.

[21] I. Kulmala *et al.*, “Local Complications After Cosmetic Breast Implant Surgery in Finland,” *Annals of Plastic Surgery*, vol. 53, no. 5, p. 413, Nov. 2004, doi: 10.1097/01.sap.0000131275.62449.c8.

- [22] M. de Boer *et al.*, “Breast Implants and the Risk of Anaplastic Large-Cell Lymphoma in the Breast,” *JAMA Oncology*, vol. 4, no. 3, pp. 335–341, Mar. 2018, doi: 10.1001/jamaoncol.2017.4510.
- [23] A. Rancati, C. Angrigiani, M. Irigo, A. Rancati, M. Bou, and J. Dorr, “Complications in breast augmentation and how to avoid them,” *J Ästhet Chir*, vol. 13, no. 4, pp. 167–171, Nov. 2020, doi: 10.1007/s12631-020-00236-8.
- [24] Y. Bachour, “Capsular Contracture in Breast Implant Surgery: Where Are We Now and Where Are We Going?,” *Aesth Plast Surg*, vol. 45, no. 3, pp. 1328–1337, Jun. 2021, doi: 10.1007/s00266-021-02141-6.
- [25] A. Gorgy *et al.*, “Implant-based breast surgery and capsular formation: when, how and why?—a narrative review,” *Annals of Translational Medicine*, vol. 11, no. 11, Art. no. 11, Oct. 2023, doi: 10.21037/atm-23-131.
- [26] J. R. O’Keefe, J. M. Wilkinson, and K. M. Spuur, “Current practice in mammographic imaging of the augmented breast in Australia,” *Journal of Medical Radiation Sciences*, vol. 67, no. 2, pp. 102–110, 2020, doi: 10.1002/jmrs.374.
- [27] D. Wang *et al.*, “3D images of the silicone implants in capsular contracture after breast augmentation using magnetic resonance imaging with SPACE sequence,” *Journal of Plastic, Reconstructive & Aesthetic Surgery*, vol. 74, no. 9, pp. 2210–2216, Sep. 2021, doi: 10.1016/j.bjps.2020.12.081.
- [28] E. Swezey, R. Shikhman, and R. Moufarrege, “Breast Implant Rupture,” in *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2024. Accessed: Aug. 01, 2024. [Online]. Available: <http://www.ncbi.nlm.nih.gov/books/NBK459308/>
- [29] E. Lake, S. Ahmad, and R. Dobrashian, “The sonographic appearances of breast implant rupture,” *Clin Radiol*, vol. 68, no. 8, pp. 851–858, Aug. 2013, doi: 10.1016/j.crad.2013.03.014.
- [30] C. for D. and R. Health, “Medical Device Reports of Breast Implant-Associated Anaplastic Large Cell Lymphoma,” *FDA*, Dec. 2023, Accessed: Jun. 11, 2024. [Online]. Available: <https://www.fda.gov/medical-devices/breast-implants/medical-device-reports-breast-implant-associated-anaplastic-large-cell-lymphoma>
- [31] P. Montemurro, P. Hedén, B. Behr, and C. Wallner, “Controllable Factors to Reduce the Rate of Complications in Primary Breast Augmentation: A Review of the Literature,” *Aesth Plast Surg*, vol. 45, no. 2, pp. 498–505, Apr. 2021, doi: 10.1007/s00266-020-01726-x.
- [32] *Nařízení Evropského parlamentu a Rady (EU) 2017/745 ze dne 5. dubna 2017 o zdravotnických prostředcích, změně směrnice 2001/83/ES, nařízení (ES) č. 178/2002 a nařízení (ES) č. 1223/2009 a o zrušení směrnic Rady 90/385/EHS a*

- 93/42/EHS (*Text s významem pro EHP*), vol. 117. 2017. Accessed: Aug. 01, 2024. [Online]. Available: <http://data.europa.eu/eli/reg/2017/745/oj/ces>
- [33] A. Newman and K. Babagbemi, “Patient-Friendly Summary of the ACR Appropriateness Criteria®: Breast Implant Evaluation: 2023 Update,” *Journal of the American College of Radiology*, vol. 21, no. 3, p. e3, Mar. 2024, doi: 10.1016/j.jacr.2023.09.005.
- [34] Chetlen, Alison et al. ACR Appropriateness Criteria®: Breast Implant Evaluation: 2023 Update. *Journal of the American College of Radiology*, 2023, vol. 20, pp. S329-S350. doi: 10.1016/j.jacr.2023.08.019
- [35] I. W. Ho, A. Chichura, H. J. Pederson, B. A. Xavier, J. Ritner, and G. S. Schwarz, “Current State of Evidence-Based Long-Term Monitoring Protocols for Breast Plastic Surgery Patients,” *Ann Surg Oncol*, Aug. 2024, doi: 10.1245/s10434-024-16003-3.
- [36] J. Beneš, D. Jiráček, and F. Vitek, *Základy lékařské fyziky*, 5., vol. 2022. Praha: Karolinum.
- [37] “The Radiology Assistant: Breast Implants.” Accessed: Aug. 27, 2024. [Online]. Available: <https://radiologyassistant.nl/breast/breast-prosthesis/breast-prosthesis-imaging#ultrasound>
- [38] A. Evans et al., “Breast ultrasound: recommendations for information to women and referring physicians by the European Society of Breast Imaging,” *Insights Imaging*, vol. 9, no. 4, Art. no. 4, Aug. 2018, doi: 10.1007/s13244-018-0636-z.
- [39] T. Ptáčková, “Analýza diagnostického postupu u žen s prsním implantátem,” Jun. 2023, Accessed: Aug. 05, 2024. [Online]. Available: <https://dspace.cvut.cz/handle/10467/112626>
- [40] S. J. Seiler et al., “Multimodality Imaging-based Evaluation of Single-Lumen Silicone Breast Implants for Rupture,” *RadioGraphics*, vol. 37, no. 2, pp. 366–382, Mar. 2017, doi: 10.1148/rg.2017160086.
- [41] B. D. Noreña-Rengifo et al., “MRI for Evaluation of Complications of Breast Augmentation,” *RadioGraphics*, vol. 42, no. 4, pp. 929–946, Jul. 2022, doi: 10.1148/rg.210096.
- [42] J. Daneš, *Screening a diagnostika karcinomu prsu*, 1. Praha: Grada, 2021.
- [43] C. M. McCarthy, A. L. Pusic, and C. L. Kerrigan, “Silicone breast implants and magnetic resonance imaging screening for rupture: do U.S. Food and Drug Administration recommendations reflect an evidence-based practice approach to patient care?,” *Plast Reconstr Surg*, vol. 121, no. 4, pp. 1127–1134, Apr. 2008, doi: 10.1097/01.prs.0000302498.44244.52.

- [44] B. Mašková, M. Rožánek, O. Gajdoš, E. Karnoub, V. Kamenský, and G. Donin, “Assessment of the Diagnostic Efficacy of Low-Field Magnetic Resonance Imaging: A Systematic Review,” *Diagnostics*, vol. 14, no. 14, Art. no. 14, Jan. 2024, doi: 10.3390/diagnostics14141564.
- [45] S. Frankel *et al.*, “Characteristics of Magnetic Resonance Sequences Used for Imaging Silicone Gel, Saline, and Gel-Saline Implants at Low Field Strengths,” *Investigative Radiology*, vol. 29, no. 8, p. 781, Aug. 1994.
- [46] P. M. Hold *et al.*, “How Should We Investigate Breast Implant Rupture?,” *The Breast Journal*, vol. 18, no. 3, pp. 253–256, 2012, doi: 10.1111/j.1524-4741.2012.01226.x.
- [47] S. Satti, A. Mohyuddin, and Q. S. B. Khalid, “DIAGNOSTIC EFFICACY OF HIGH-RESOLUTION ULTRASOUND IN THE ASSESSMENT OF BREAST IMPLANTS,” Apr. 2020. Accessed: Jun. 24, 2024. [Online]. Available: <https://www.semanticscholar.org/paper/DIAGNOSTIC-EFFICACY-OF-HIGH-RESOLUTION-ULTRASOUND-Satti-Mohyuddin/cfe248b17b63318e95e64ede7d539ed1540f861e>
- [48] D. Rukanskienė, G. Bytautaitė, A. Česnauskaitė, L. Pilipaitytė, T. Aštrauskas, and E. Jonaitienė, “The Value of Ultrasound in the Evaluation of the Integrity of Silicone Breast Implants,” *Medicina*, vol. 57, no. 5, Art. no. 5, May 2021, doi: 10.3390/medicina57050440.
- [49] P. Bogetti *et al.*, “Novel decision algorithm for the diagnosis of silicone gel breast implant ruptures,” *Eur J Plast Surg*, vol. 41, no. 6, pp. 677–684, Dec. 2018, doi: 10.1007/s00238-018-1434-z.
- [50] R. Sinha and F. Singh, “Ultrasound breast implant rupture – how accurate are we?,” *Clinical Radiology*, vol. 72, p. S1, Sep. 2017, doi: 10.1016/j.crad.2017.06.040.
- [51] A. Stivala *et al.*, “Efficacy of ultrasound, mammography and magnetic resonance imaging in detecting breast implant rupture: A retrospective study of 175 reconstructive and aesthetic sub-pectoral breast augmentation cases,” *Journal of Plastic, Reconstructive & Aesthetic Surgery*, vol. 70, no. 11, pp. 1520–1526, Nov. 2017, doi: 10.1016/j.bjps.2017.05.051.
- [52] T. R. C. Johnson *et al.*, “Dual-energy CT for the evaluation of silicone breast implants,” *Eur Radiol*, vol. 23, no. 4, pp. 991–996, Apr. 2013, doi: 10.1007/s00330-012-2667-z.
- [53] K. N. Glazebrook, S. Leng, S. R. Jacobson, and C. M. McCollough, “Dual-Energy CT for Evaluation of Intra- and Extracapsular Silicone Implant Rupture,”

- Case Reports in Radiology*, vol. 2016, no. 1, p. 6323709, 2016, doi: 10.1155/2016/6323709.
- [54] S. Juanpere, E. Perez, O. Huc, N. Motos, J. Pont, and S. Pedraza, “Imaging of breast implants—a pictorial review,” *Insights Imaging*, vol. 2, no. 6, pp. 653–670, Aug. 2011, doi: 10.1007/s13244-011-0122-3.
- [55] J. W. Song, H. M. Kim, L. T. Bellfi, and K. C. Chung, “The Effect of Study Design Biases on the Diagnostic Accuracy of Magnetic Resonance Imaging for Detecting Silicone Breast Implant Ruptures: A Meta-Analysis,” *Plastic and Reconstructive Surgery*, vol. 127, no. 3, p. 1029, Mar. 2011, doi: 10.1097/PRS.0b013e3182043630.
- [56] L. R. Hölmich, I. Vejborg, C. Conrad, S. Sletting, and J. K. McLaughlin, “The diagnosis of breast implant rupture: MRI findings compared with findings at explantation,” *European Journal of Radiology*, vol. 53, no. 2, pp. 213–225, Feb. 2005, doi: 10.1016/j.ejrad.2004.03.012.
- [57] L. Salchenberger, E. R. Venta, and L. A. Venta, “Using neural networks to aid the diagnosis of breast implant rupture,” *Computers & Operations Research*, vol. 24, no. 5, pp. 435–444, May 1997, doi: 10.1016/S0305-0548(96)00064-0.
- [58] L. A. Venta, L. M. Salchenberger, and E. R. Venta, “Improved diagnosis of breast implant rupture with sonographic findings and artificial neural networks,” *Academic Radiology*, vol. 5, no. 4, pp. 238–244, Apr. 1998, doi: 10.1016/S1076-6332(98)80222-5.
- [59] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, Jun. 2016, doi: 10.1109/CVPR.2016.90.
- [60] C. Hillard, J. D. Fowler, R. Barta, and B. Cunningham, “Silicone breast implant rupture: a review,” *Gland Surgery*, vol. 6, no. 2, Art. no. 2, Apr. 2017, doi: 10.21037/gs.2016.09.12.
- [61] P. R. Bauer, B. J. Krajicek, C. E. Daniels, S. S. Shah, and J. H. Ryu, “Silicone breast implant-induced lymphadenopathy: 18 Cases,” *Respiratory Medicine CME*, vol. 4, no. 3, pp. 126–130, Jan. 2011, doi: 10.1016/j.rmedc.2011.01.001.
- [62] P. Pirompanich *et al.*, “Acute respiratory distress syndrome following breast augmentation managed by delayed veno-venous extracorporeal membrane oxygenation,” *Lung India*, vol. 40, no. 4, p. 356, Aug. 2023, doi: 10.4103/lungindia.lungindia_63_23.

- [63] A. Azeem, S. Khuwaja, R. Parthvi, and T. Persaud, “Pulmonary fibrosis and embolism secondary to silicon implant leak,” *BMJ Case Rep*, vol. 12, no. 6, p. e229470, Jun. 2019, doi: 10.1136/bcr-2019-229470.
- [64] A. Arora, H. Inaty, S. Mukhopadhyay, M. Abu-Hijleh, and A. C. Mehta, “Chronic Pulmonary Silicone Embolism Related to Saline Breast Implants,” *Annals ATS*, vol. 13, no. 1, pp. 139–141, Jan. 2016, doi: 10.1513/AnnalsATS.201509-575LE.
- [65] G. Janszen, M. Arnoldi, V. Vinci, M. Klinger, and L. Di Landro, “On the Safety of Implanted Breast Prostheses in Accidental Impacts,” *Materials*, vol. 16, no. 13, Art. no. 13, Jan. 2023, doi: 10.3390/ma16134807.
- [66] A. Krajcová, K. Hurt, R. Kufa, and M. Molitor, “Ruptura prsního implantátu: sportovní trauma prsu,” *Ceska gynekologie / Ceska lekarska spolecnost J. Ev. Purkyne*, vol. 85, pp. 116–119, Sep. 2020.
- [67] N. Handel, M. E. Garcia, and R. Wixtrom, “Breast Implant Rupture: Causes, Incidence, Clinical Impact, and Management,” *Plastic and Reconstructive Surgery*, vol. 132, no. 5, p. 1128, Nov. 2013, doi: 10.1097/PRS.0b013e3182a4c243.
- [68] N. A. G. Ramião, P. A. L. de S. Martins, M. da L. Barroso, D. C. Santos, F. B. da R. Pereira, and A. A. Fernandes, “Mechanical Performance of Poly Implant Prosthesis (PIP) Breast Implants: A Comparative Study,” *Aesth Plast Surg*, vol. 41, no. 2, pp. 250–264, Apr. 2017, doi: 10.1007/s00266-017-0776-4.
- [69] U. Wazir, A. Kasem, and K. Mokbel, “The Clinical Implications of Poly Implant Prothèse Breast Implants: An Overview,” *Arch Plast Surg*, vol. 42, no. 01, pp. 4–10, Jan. 2015, doi: 10.5999/aps.2015.42.1.4.
- [70] J. Deng, W. Dong, R. Socher, L.-J. Li, Kai Li, and Li Fei-Fei, “ImageNet: A large-scale hierarchical image database,” *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 248–255, Jun. 2009, doi: 10.1109/CVPR.2009.5206848.
- [71] K. He, X. Zhang, S. Ren, and J. Sun, “Identity Mappings in Deep Residual Networks,” in *Computer Vision – ECCV 2016*, B. Leibe, J. Matas, N. Sebe, and M. Welling, Eds., Cham: Springer International Publishing, 2016, pp. 630–645. doi: 10.1007/978-3-319-46493-0_38.
- [72] F. Chollet, “Xception: Deep Learning with Depthwise Separable Convolutions,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Jul. 2017, pp. 1800–1807. doi: 10.1109/CVPR.2017.195.
- [73] Rendyk, “Tuning the Hyperparameters and Layers of Neural Network Deep Learning,” *Analytics Vidhya*. Accessed: Oct. 08, 2024. [Online]. Available:

<https://www.analyticsvidhya.com/blog/2021/05/tuning-the-hyperparameters-and-layers-of-neural-network-deep-learning/>

[74] “Confusion Matrix - an overview | ScienceDirect Topics.” Accessed: Nov. 01, 2024.[Online].Available:<https://www.sciencedirect.com/topics/engineering/confusion-matrix>

[75] G. M. Foody, “Challenges in the real world use of classification accuracy metrics: From recall and precision to the Matthews correlation coefficient,” *PLOS ONE*, vol. 18, no. 10, p. e0291908, 10 2023, doi: 10.1371/journal.pone.0291908.

[76] Anjana, “Decluttering the performance measures of classification models,” Analytics Vidhya. Accessed: Oct. 21, 2024. [Online]. Available: <https://www.analyticsvidhya.com/blog/2020/12/decluttering-the-performance-measures-of-classification-models/>

[77] D. M. W. Powers, “Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation,” Oct. 11, 2020, *arXiv*: arXiv:2010.16061. doi: 10.48550/arXiv.2010.16061.

[78] M. Dehghan Rouzi *et al.*, “Breast Cancer Detection with an Ensemble of Deep Learning Networks Using a Consensus-Adaptive Weighting Method,” *Journal of Imaging*, vol. 9, no. 11, Art. no. 11, Nov. 2023, doi: 10.3390/jimaging9110247.

[79] M. Ragab, A. Albukhari, J. Alyami, and R. F. Mansour, “Ensemble Deep-Learning-Enabled Clinical Decision Support System for Breast Cancer Diagnosis and Classification on Ultrasound Images,” *Biology*, vol. 11, no. 3, Art. no. 3, Mar. 2022, doi: 10.3390/biology11030439.

[80] M. Shah, N. Tanna, and L. Margolies, “Magnetic Resonance Imaging of Breast Implants,” *Topics in Magnetic Resonance Imaging*, vol. 23, no. 6, p. 345, Dec. 2014, doi: 10.1097/RMR.000000000000039.

[81] N. Zingaretti *et al.*, “Determinants of surgeon choice in cases of suspected implant rupture following mastectomy or aesthetic breast surgery: Clinical implications,” *Medicine*, vol. 99, no. 27, p. e21134, Jul. 2020, doi: 10.1097/MD.00000000000021134.

[82] A. Alwosheel, S. van Cranenburgh, and C. G. Chorus, “Is your dataset big enough? Sample size requirements when using artificial neural networks for discrete choice analysis,” *Journal of Choice Modelling*, vol. 28, pp. 167–182, Sep. 2018, doi: 10.1016/j.jocm.2018.07.002.

[83] T. Islam, Md. S. Hafiz, J. R. Jim, Md. M. Kabir, and M. F. Mridha, “A systematic review of deep learning data augmentation in medical imaging: Recent advances and

future research directions,” *Healthcare Analytics*, vol. 5, p. 100340, Jun. 2024, doi: 10.1016/j.health.2024.100340.

[84] K. D. Kurz, Ø. Kallevåg, K. Austrått, B. Styr, J. B. Leiknes, and P. Krøger, “Artifacts on Magnetic Resonance Imaging from Electronic Identification Enablement in Silicone Gel Implants Are Not Negligible,” *Plastic and Reconstructive Surgery – Global Open*, vol. 9, no. 11, p. e3941, Nov. 2021, doi: 10.1097/GOX.0000000000003941.

[85] C. for D. and R. Health, “UDI Compliance Policies and UDI Rule Compliance Dates,” *FDA*, Sep. 2024, Accessed: Oct. 29, 2024. [Online]. Available: <https://www.fda.gov/medical-devices/unique-device-identification-system-udi-system/udi-compliance-policies-and-udi-rule-compliance-dates>

[86] “Regulation - 2017/745 - EN - Medical Device Regulation - EUR-Lex.” Accessed: Oct. 29, 2024. [Online]. Available: <https://eur-lex.europa.eu/eli/reg/2017/745/oj>

Příloha A: Rozhodnutí etické komise



ETICKÁ KOMISE
FAKULNÍ NEMOCNICE KRÁLOVSKÉ VINOHRADY
MEDICAL FACULTY OF CHARLES UNIVERSITY

ROZHODNUTÍ ETICKÉ KOMISE FAKULNÍ NEMOCNICE KRÁLOVSKÉ VINOHRADY

EK-R/02/0/2021

Věc:

„Žádost o poskytnutí obrazové dokumentace ze zobrazovacích vyšetření u pacientek s prsním implantátem“

Žadatel: Ing. Barbora Klíčová

Řešitel ve FNKV: MUDr. Josef Bárta, Radiodiagnostická klinika

Etická komise na svém zasedání dne **1. prosince 2021** projednala žádost o poskytnutí obrazové dokumentace ze zobrazovacích vyšetření u pacientek s prsním implantátem pro potřeby výzkumu pro zpracování dizertační práce s názvem „Identifikace poškození prsního implantátu“, která bude zpracována na Fakultě biomedicínského inženýrství ČVUT.

Na základě hlasování EK vydává ☒ **Souhlasné stanovisko** ☐ **Nesouhlasné stanovisko**

Upozornění ke stanovisku EK FNKV:

- V případě, že z projektu vzejde publikace, je hlavní řešitel povinen publikaci dedikovat FNKV.

Seznam členů etické komise

Jméno a příjmení	Muž/ Žena	Odbornost	Zaměstnanec zřizovatele EK*		Funkce v EK	Přítomen		Hlasoval	
			Ano	Ne		Ano	Ne	Ano	Ne
prof. MUDr. Jan Pachel, CSc.	M	anesteziolog	☒	☐	předseda	☒	☐	☒	☐
MUDr. Martin Herold	M	kardiolog	☒	☐	místopředseda	☒	☐	☒	☐
MUDr. Milan Brychta	M	onkolog	☒	☐	člen	☒	☐	☒	☐
Jarmila Folprechtová	F	zástupce pacientů	☐	☒	člen	☒	☐	☒	☐
PhDr. Libuše Gavlasová	F	zdravotní sestra	☒	☐	člen	☒	☐	☒	☐
Dana Kovandová	F	tajemnice	☒	☐	člen	☒	☐	☒	☐
MUDr. Eva Krpenská	M	chirurg	☒	☐	člen	☒	☐	☒	☐
PharmDr. Lukáš Lázníčka	M	lékárník	☒	☐	člen	☒	☐	☒	☐
MUDr. Nikola Mejzlíková	F	internistka	☒	☐	člen	☒	☐	☒	☐
Luboš Olejář	M	zástupce pacientů	☐	☒	člen	☒	☐	☒	☐
MUDr. Leo Slavkovský	M	anesteziolog	☒	☐	člen	☒	☐	☒	☐

(pozn: *Zaměstnanec zřizovatele EK)

Etická komise prohlašuje, že byla ustavena a pracuje podle jednacího řádu v souladu se správnou klinickou praxí (GCP) a platnými právními předpisy: ☒ Ano ☐ Ne


1. 12. 2021
Datum

Prof. MUDr. Jan Pachel, CSc.
předseda EK FNKV


Podpis předsedy/místopředsedy EK

FAKULTNÍ NEMOCNICE
KRÁLOVSKÉ VINOHRADY
Šrobárova 50, 100 34 Praha 10
ETICKÁ KOMISE


Příloha B: Struktura neuronových sítí



Obrázek B.1 Struktura NN ResNet-18



Obrázek B.2 Struktura NN ResNet-50



Obrázek B.3 Struktura NN Xception

Příloha C: Výsledky

Tabulka C.1 ResNet18: Nastavené hyperparametry a použité augmentační techniky u jednotlivých modelů

Model	Velikost			Filtr	Neuronová sít'	Váhy tříd	Optimalizátor	Max epochs	Velikost Mini- batch	Validation frequency	Augmenter rot	Augmenter X	Augmenter Y
Model1	500	500	3	-	resnet18	[1, 25]	sgdm	10	16	10	-180; 180	-50; 50	-50; 50
Model10	224	224	3	-	resnet18	[1, 25]	adam	50	32	10	-180; 180	-15; 15	-15; 15
Model10X	224	224	3	-	resnet18	[1, 25]	adam	50	32	10	-180; 180	-15; 15	-15; 15
Model11	224	224	3	-	resnet18	[1, 25]	adam	50	32	10	-10; 10	-5; 5	-5; 5
Model12	224	224	3	-	resnet18	[1, 25]	adam	100	16	10	-10; 10	-5; 5	-5; 5
Model13	224	224	3	-	resnet18	[1, 25]	adam	50	8	10	-15; 15	-10; 10	-10; 10
Model14	224	224	3	Edge (32, 900)	resnet18	[1, 25]	adam	50	8	10	-15; 15	-10; 10	-10; 10
Model15	224	224	3	-	resnet18	[1, 5]	adam	30	8	10	-15; 15	-10; 10	-10; 10
Model16	224	224	3	-	resnet18	[1, 5]	adam	30	8	10	-15; 15	-10; 10	-10; 10
Model16X	224	224	3	-	resnet18	[1, 5]	adam	30	8	30	-15; 15	-10; 10	-10; 10
Model17	224	224	3	Edge (32, 900)	resnet18	[1, 5]	adam	10	8	10	-180; 180	-10; 10	-10; 10
Model18	224	224	3	Edge (32, 900)	resnet18	[1, 5]	adam	10	16	10	-180; 180	-10; 10	-10; 10
Model19	224	224	3	-	resnet18	[1, 2]	sgdm	10	16	10	-180; 180	-10; 10	-10; 10
Model11X	500	500	3	-	resnet18	[1, 25]	sgdm	10	16	10	-180; 180	-50; 50	-50; 50
Model2	500	500	3	-	resnet18	[1, 25]	sgdm	15	16	10	-180; 180	-50; 50	-50; 50

Model	Velikost			Filtr	Neuronová sít'	Váhy tříd	Optimalizátor	Max epochs	Velikost Mini- batch	Validation frequency	Augmenter rot	Augmenter X	Augmenter Y
Model20	224	224	3	-	resnet18	[1, 2]	adam	10	16	10	-180; 180	-10; 10	-10; 10
Model21	224	224	3	Edge (32, 900)	resnet18	[1, 2]	adam	10	16	10	-180; 180	-10; 10	-10; 10
Model22	224	224	3	-	resnet18	[1, 2]	adam	10	32	10	-180; 180	-10; 10	-10; 10
Model23	224	224	3	-	resnet18	[1, 2]	adam	30	32	10	-180; 180	-10; 10	-10; 10
Model24	224	224	3	-	resnet18	[1, 2]	adam	40	32	20	-180; 180	-5; 5	-5; 5
Model25	224	224	3	Edge (32, 900)	resnet18	[1, 2]	adam	40	32	20	-180; 180	-5; 5	-5; 5
Model2X	500	500	3	-	resnet18	[1, 25]	sgdm	15	16	10	-180; 180	-50; 50	-50; 50
Model2Xa	500	500	3	-	resnet18	[1, 50]	sgdm	15	16	10	-180; 180	-50; 50	-50; 50
Model2Xb	500	500	3	Edge (32, 900)	resnet18	[1, 50]	sgdm	20	16	10	-180; 180	-50; 50	-50; 50
Model3	500	500	3	-	resnet18	[1, 25]	sgdm	20	32	10	-180; 180	-50; 50	-50; 50
Model3X	500	500	3	-	resnet18	[1, 25]	sgdm	20	32	10	-180; 180	-50; 50	-50; 50
Model4	500	500	3	Edge (32, 900)	resnet18	[1, 25]	sgdm	20	16	10	-180; 180	-50; 50	-50; 50
Model4X	500	500	3	Edge (32, 900)	resnet18	[1, 25]	sgdm	20	16	10	-180; 180	-50; 50	-50; 50
Model4Xa	500	500	3	-	resnet18	[1, 25]	sgdm	20	16	10	-180; 180	-50; 50	-50; 50
Model4Xb	500	500	3	-	resnet18	[1, 50]	sgdm	20	16	10	-180; 180	-50; 50	-50; 50
Model4Xc	500	500	3	-	resnet18	[1, 50]	adam	20	16	10	-180; 180	-50; 50	-50; 50
Model8	500	500	3	-	resnet18	[1, 25]	adam	15	16	10	-180; 180	-50; 50	-50; 50
Model9	500	500	3	-	resnet18	[1, 25]	adam	50	16	10	-180; 180	-15; 15	-15; 15

Tabulka C.2 ResNet18: Výsledky

Model	Trénovací data			Validační data			Testovací data		
	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR
Model1	0.95757	0.92027	0.98487	0.9419	0.91389	0.96356	0.91827	0.94811	0.77805
Model10	0.96107	0.92267	0.98408	0.94919	0.93151	0.94159	0.93711	0.95843	0.8169
Model10X	0.97258	0.94899	0.97844	0.94786	0.94305	0.92173	0.93216	0.96779	0.79048
Model11	0.94791	0.9246	0.96125	0.90576	0.94123	0.70589	0.85274	0.96508	0.48124
Model12	0.94956	0.8948	0.9948	0.92068	0.91027	0.85605	0.87378	0.95169	0.60107
Model13	0.96528	0.92917	0.99344	0.93807	0.93941	0.88141	0.90639	0.96635	0.6818
Model14	0.8925	0.84027	0.97303	0.89927	0.84672	0.98127	0.85968	0.82139	0.91271
Model15	0.96172	0.96846	0.93096	0.91856	0.97363	0.70107	0.87331	0.98394	0.52563
Model16	0.96072	0.92748	0.98279	0.93832	0.92694	0.91734	0.92706	0.93803	0.83314
Model16X	0.96927	0.94323	0.97887	0.93937	0.95343	0.84735	0.89048	0.97232	0.61645
Model17	0.94691	0.94451	0.92647	0.94513	0.94637	0.90159	0.88663	0.97137	0.61583
Model18	0.94208	0.94252	0.91418	0.94202	0.95007	0.89253	0.90305	0.93416	0.76399
Model19	0.9244	0.97689	0.82531	0.86678	0.98386	0.51299	0.82351	0.98871	0.3092
Model1X	0.94549	0.90266	0.98874	0.93591	0.89916	0.9731	0.931	0.9289	0.86859
Model2	0.9664	0.93476	0.98661	0.94616	0.94187	0.90864	0.92615	0.963	0.78046
Model20	0.89078	0.99064	0.59295	0.86351	0.99128	0.44094	0.8176	0.99564	0.27326
Model21	0.93889	0.93353	0.91031	0.94508	0.93466	0.9318	0.92775	0.93457	0.85777
Model22	0.86752	0.99533	0.54075	0.83896	0.99616	0.35075	0.80077	0.99797	0.20164
Model23	0.93054	0.98514	0.79171	0.90495	0.98657	0.66292	0.85917	0.98851	0.46736
Model24	0.9067	0.98997	0.71231	0.86847	0.99429	0.47201	0.81388	0.99514	0.26993
Model25	0.94652	0.9799	0.85438	0.91706	0.98438	0.68832	0.86394	0.98332	0.49715

Model	Trénovací data			Validační data			Testovací data		
	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR
Model2X	0.96151	0.92169	0.9925	0.94842	0.92533	0.95451	0.9136	0.95668	0.73189
Model2Xa	0.96185	0.9259	0.98216	0.94909	0.92691	0.95497	0.94247	0.94801	0.86971
Model2Xb	0.96392	0.92589	0.99269	0.95506	0.93607	0.9529	0.93877	0.94364	0.86492
Model3	0.96606	0.94252	0.97356	0.94191	0.94318	0.90639	0.91779	0.96067	0.75505
Model3X	0.96325	0.93446	0.98036	0.93733	0.93388	0.91393	0.92398	0.95441	0.78658
Model4	0.96413	0.93671	0.98313	0.95073	0.94295	0.92016	0.92735	0.95009	0.80774
Model4X	0.96928	0.95424	0.96711	0.95333	0.95744	0.90283	0.91845	0.96622	0.74513
Model4Xa	0.97122	0.95013	0.97756	0.94473	0.95308	0.89666	0.91553	0.96629	0.73327
Model4Xb	0.95716	0.91485	0.99253	0.94287	0.91688	0.95367	0.9316	0.94835	0.82341
Model4Xc	0.96317	0.9278	0.97681	0.94467	0.91227	0.96371	0.93603	0.9528	0.83683
Model8	0.94878	0.92713	0.94849	0.92368	0.89854	0.94907	0.90875	0.94286	0.77608
Model9	0.9409	0.90156	0.97348	0.935	0.90637	0.94688	0.91593	0.9458	0.78653

Tabulka C.3 ResNet-50: Nastavené hyperparametry a použité augmentační techniky u jednotlivých modelů

Model	Velikost			Filtr	Neuronová sít'	Váhy tříd	Optimalizátor	Max epochs	Velikost Mini- batch	Validation frequency	Augmenter rot	Augmenter X	Augmenter Y
Model26	224	224	3	-	resnet50	[1, 2]	adam	40	32	20	-180; 180	-5; 5	-5; 5
Model27	224	224	3	Edge (32, 900)	resnet50	[1, 2]	adam	50	32	10	-180; 180	-5; 5	-5; 5
Model28	224	224	3	-	resnet50	[1, 2]	sgdm	50	32	10	-180; 180	-5; 5	-5; 5
Model29	224	224	3	-	resnet50	[1, 2]	sgdm	100	32	10	-180; 180	-5; 5	-5; 5
Model30	224	224	3	-	resnet50	[1, 5]	sgdm	100	16	10	-180; 180	-5; 5	-5; 5
Model31	224	224	3	-	resnet50	[1, 2]	sgdm	100	16	30	-180; 180	-5; 5	-5; 5
Model5	500	500	3	Edge (32, 900)	resnet50	[1, 25]	sgdm	10	16	10	-180; 180	-50; 50	-50; 50
Model5X	500	500	3	Edge (32, 900)	resnet50	[1, 25]	sgdm	10	16	10	-180; 180	-50; 50	-50; 50
Model5Xa	500	500	3	-	resnet50	[1, 50]	sgdm	10	16	10	-180; 180	-50; 50	-50; 50
Model5Xb	500	500	3	Edge (32, 900)	resnet50	[1, 50]	sgdm	10	16	10	-180; 180	-50; 50	-50; 50
Model6	500	500	3	-	resnet50	[1, 25]	sgdm	10	16	10	-180; 180	-50; 50	-50; 50
Model7	500	500	3	-	resnet50	[1, 25]	adam	15	16	10	-180; 180	-50; 50	-50; 50
Model7Xa	500	500	3	Edge (32, 900)	resnet50	[1, 50]	adam	15	16	10	-180; 180	-50; 50	-50; 50
Model7Xb	500	500	3	-	resnet50	[1, 50]	adam	15	16	10	-180; 180	-50; 50	-50; 50

Tabulka C.4 ResNet-50: Výsledky

Model	Trénovací data			Validační data			Testovací data		
	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR
Model26	0.93729	0.98882	0.78686	0.90248	0.98865	0.65715	0.84367	0.99182	0.38468
Model27	0.95086	0.96844	0.89959	0.93052	0.97629	0.7748	0.88051	0.97794	0.56961
Model28	0.9511	0.98943	0.86669	0.88319	0.98733	0.55798	0.8619	0.98778	0.48009
Model29	0.96303	0.99026	0.90708	0.87696	0.98779	0.53478	0.84475	0.98913	0.40718
Model30	0.98769	0.98892	0.96957	0.89673	0.98455	0.58153	0.87661	0.98801	0.52965
Model31	0.97397	0.99028	0.93597	0.8889	0.98655	0.58222	0.86313	0.98879	0.47339
Model5	0.96216	0.92739	0.98095	0.95646	0.93663	0.95384	0.93692	0.94253	0.86268
Model5X	0.96447	0.93997	0.97082	0.95277	0.9516	0.90404	0.9158	0.96077	0.74521
Model5Xa	0.96078	0.91502	0.99246	0.94108	0.91381	0.95773	0.93383	0.94085	0.84733
Model5Xb	0.9624	0.93092	0.98234	0.95461	0.94305	0.92505	0.93514	0.95049	0.84245
Model6	0.95789	0.91373	0.9921	0.93521	0.91527	0.93702	0.92059	0.94393	0.79772
Model7	0.95745	0.90994	0.98078	0.94936	0.92157	0.94597	0.91597	0.96269	0.73814
Model7Xa	0.92958	0.88142	0.97052	0.9387	0.90078	0.96251	0.92023	0.93223	0.8211
Model7Xb	0.94238	0.88987	0.98071	0.9268	0.87973	0.97421	0.92995	0.91721	0.89041

Tabulka C.5 Nastavené hyperparametry a použité augmentační techniky u jednotlivých modelů

Model	Velikost			Filtr	Neuronová sít'	Váhy tříd	Optimalizátor	Max epochs	Velikost Mini- batch	Validation frequency	Augmenter rot	Augmenter X	Augmenter Y
Model32	299	299	3		xception	[1, 2]	sgdm	100	16	30	-180; 180	-5; 5	-5; 5
Model33	299	299	3		xception	[1, 25]	sgdm	50	8	30	-180; 180	-5; 5	-5; 5
Model33X	299	299	3		xception	[1, 25]	sgdm	50	8	30	-180; 180	-5; 5	-5; 5
Model34	299	299	3		xception	[1, 2]	sgdm	100	16	30	-180; 180	-15; 15	-15; 15
Model35	299	299	3	Edge (32, 900)	xception	[1, 2]	sgdm	50	16	20	-180; 180	-15; 15	-15; 15
Model36	299	299	3		xception	[1, 2]	sgdm	50	16	30	-180; 180	-15; 15	-15; 15
Model37	299	299	3		xception	[1, 2]	adam	50	16	30	-180; 180	-15; 15	-15; 15
Model38	299	299	3		xception	[1, 25]	adam	50	32	30	-180; 180	-10; 10	-10; 10
Model38X	299	299	3		xception	[1, 5]	adam	50	32	30	-180; 180	-10; 10	-10; 10
Model38Xa	299	299	3	Edge (32, 900)	xception	[1, 5]	adam	50	32	30	-180; 180	-10; 10	-10; 10
Model38Xb	299	299	3	Edge (32, 900)	xception	[1, 50]	adam	50	32	30	-180; 180	-10; 10	-10; 10
Model38Xc	299	299	3		xception	[1, 50]	adam	50	32	30	-180; 180	-10; 10	-10; 10
Model38Xd	299	299	3		xception	[1, 50]	sgdm	30	32	10	-180; 180	-10; 10	-10; 10

Tabulka C.6 Xception: Výsledky


Model	Trénovací data			Validační data			Testovací data		
	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR
Model32	0.94677	0.98642	0.85982	0.87874	0.98631	0.50181	0.84149	0.98864	0.38656
Model33	0.9747	0.93749	0.9964	0.94379	0.94587	0.89918	0.91697	0.96432	0.73615
Model33X	0.97661	0.95577	0.98161	0.93881	0.95824	0.85527	0.91451	0.96723	0.72974
Model34	0.93937	0.98821	0.83507	0.87383	0.99012	0.48762	0.83622	0.99165	0.36509
Model35	0.92781	0.98351	0.80453	0.9031	0.98275	0.67222	0.84526	0.98597	0.41953
Model36	0.92631	0.98576	0.79626	0.87818	0.98676	0.54677	0.84559	0.98702	0.41795
Model37	0.94632	0.98183	0.85254	0.91431	0.98629	0.69947	0.85543	0.98598	0.4577
Model38	0.97487	0.94935	0.98666	0.95333	0.95544	0.90868	0.92614	0.96848	0.75722
Model38X	0.94259	0.97978	0.8365	0.91621	0.98502	0.70596	0.87635	0.98954	0.52418
Model38Xa	0.96017	0.982	0.89969	0.92178	0.98562	0.70143	0.85842	0.986	0.45831
Model38Xb	0.95664	0.91281	0.98883	0.95674	0.9228	0.9799	0.93594	0.92651	0.89821
Model38Xc	0.97469	0.94053	0.99656	0.95069	0.93193	0.95943	0.94579	0.95448	0.86774
Model38Xd	0.94845	0.90075	0.98842	0.92376	0.89458	0.94728	0.91522	0.92216	0.83376

Tabulka C.7 Výsledky kombinovaných modelů


Kombinovaný model	Použité modely	Trénovací data			Validační data			Testovací data		
		Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR	Acc _{mf}	TPR	TNR
CombinedModel1	Model5, Model10, Model2Xb, Model2Xa, Model38Xc	0.97214	0.93413	0.99641	0.96231	0.93994	0.9674	0.95217	0.95865	0.87977
CombinedModel2	Model1, Model10, Model3	0.97118	0.93529	0.99255	0.95477	0.93596	0.95622	0.94178	0.96075	0.83872
CombinedModel3	Model5, Model38Xc, Model2Xa	0.97233	0.93549	0.9945	0.96032	0.93828	0.96814	0.95367	0.95656	0.88886
CombinedModel4	Model5, Model38Xc, Model2Xa, Model5Xb, Model7Xa	0.96885	0.93147	0.99278	0.964	0.9406	0.96969	0.94817	0.95473	0.87601
CombinedModel5	Model2Xa, Model38Xc, Model2Xa, Model5Xb, Model38Xd	0.96872	0.93029	0.99223	0.95618	0.93293	0.96387	0.94938	0.95417	0.88099
CombinedModel6	Model21, Model7Xb, Model2Xa, Model4Xc, Model38Xc	0.96793	0.93204	0.9875	0.95658	0.92877	0.97294	0.95096	0.95355	0.88654
CombinedModel7	Model2Xb, Model2Xa, Model38Xc	0.97456	0.93796	0.99754	0.95753	0.93543	0.96722	0.94882	0.95709	0.87294

Příloha D: Ukázka výstupů z algoritmu


Původní obrázek




Předpovězená maska




Předpovězená maska



Originální maska




Původní obrázek




Předpovězená maska




Předpovězená maska




Originální maska




Původní obrázek




Předpovězená maska




Předpovězená maska




Originální maska




Původní obrázek



Předpovězená maska



Předpovězená maska



Originální maska

