



**MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CIÊNCIAS DA SAÚDE DE PORTO ALEGRE
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS DA INFORMAÇÃO E
GESTÃO EM SAÚDE**

Bernardo Cecchetto

**Método computacional para o controle de qualidade de
mamógrafos a partir de imagens obtidas com objetos simuladores
de mama**

Porto Alegre

2023

Bernardo Cecchetto

**Método computacional para o controle de qualidade de
mamógrafos a partir de imagens obtidas com objetos simuladores
de mama**

Dissertação no Programa de Mestrado Acadêmico em
Tecnologias da Informação e Gestão em Saúde da
Universidade Federal de Ciências da Saúde de Porto
Alegre.

Orientadora: Profa. Dra. Viviane Rodrigues Botelho

Coorientadoras: Profa. Dra. Thatiane Alves Pianoschi Alva
e Profa. Dra. Carla Diniz Lopes Becker

Porto Alegre

2023

Catalogação na Publicação

Cecchetto, Bernardo

Método computacional para o controle de qualidade de mamógrafos a partir de imagens obtidas com objetos simuladores de mama / Bernardo Cecchetto. -- 2023.

95 p. : il., graf., tab. ; 30 cm.

Tese (doutorado) -- Universidade Federal de Ciências da Saúde de Porto Alegre, Programa de Pós-Graduação em Tecnologias da Informação e Gestão em Saúde, 2023.

Orientador(a): Viviane Rodrigues Botelho ;
coorientador(a): Carla Diniz Lopes Becker, Thatiane Pianoschi Alves.

1. Deep Learning. 2. Mamografia. 3. Controle de Qualidade. 4. Processamento de Imagens. 5. Machine Learning. I. Título.

Sistema de Geração de Ficha Catalográfica da UFCSPA com os dados fornecidos pelo(a) autor(a).

Bernardo Cecchetto

Método computacional para o controle de qualidade de mamógrafos a partir de imagens obtidas com simuladores de mama

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Tecnologias da Informação e Gestão em Saúde da Universidade Federal de Ciências da Saúde de Porto Alegre como requisito parcial para a obtenção do título de Mestre em Tecnologia da Informação e Gestão em Saúde.

Orientadora: Profa. Dra. Viviane Rodrigues Botelho

Co-orientadoras: Prof. Dr. Thatiane Alves Pianoschi Alva e Profa. Dra. Carla Diniz Lopes Becker

Aprovada em: _____ de _____ de 2023

BANCA EXAMINADORA:

Prof. Dr. Alexandre Bonatto
Universidade Federal de Ciências da Saúde de Porto Alegre

Prof. Dr. Sílvio César Cazella
Universidade Federal de Ciências da Saúde de Porto Alegre

Profa. Dra. Chiara das Dores do Nascimento
Universidade Católica de Pelotas

AGRADECIMENTOS

Primeiramente, expresso meu profundo agradecimento a todos os meus familiares, amigos e minhas orientadoras pelo inestimável apoio e incentivo ao longo desta jornada. Essa trajetória de pesquisa foi repleta de desafios, frustrações e árduo trabalho, todos eles superados com sucesso. Ingressar no Programa de Pós-graduação em Tecnologia da Informação e Gestão em Saúde (PPG-TIG) representou um significativo desafio em minha vida, exigindo um equilíbrio cuidadoso entre a esfera pessoal, profissional e acadêmica. O conhecimento técnico adquirido durante o desenvolvimento desta pesquisa não se limitou apenas ao seu escopo, mas também se estendeu ao meu âmbito profissional e, até mesmo, em contextos internacionais.

Gostaria de expressar minha gratidão às pessoas que estiveram ao meu lado nos momentos de frustração e questionamento, em especial à minha namorada, Natália Cristina Soares Lemes, cujo apoio e companhia foram constantes durante toda a minha jornada diária. Agradeço também à minha mãe e meu pai, Fátima Helena Cecchetto e Flávio Cecchetto, cujo apoio incondicional e palavras de encorajamento sempre fizeram a diferença e me motivaram a nunca desistir.

Não posso deixar de agradecer às minhas orientadoras, Professora Doutora Viviane Rodrigues Botelho, Professora Doutora Thatiane Alves Pianoschi Alva e Professora Doutora Carla Diniz Lopes Becker, que depositaram confiança em meu trabalho, forneceram orientações valiosas e apoio necessário para que o projeto fosse conduzido na direção correta.

A ciência da computação e a academia tiveram um impacto direto e profundamente positivo em minha vida. Elas me permitiram visualizar com clareza o caminho profissional que desejava trilhar, meus objetivos e sonhos mais ambiciosos, que pareciam inalcançáveis há apenas dois anos, quando concluí minha graduação em Física Médica e me inseri no mestrado com o sonho de me tornar um programador, uma área completamente distinta de minha formação inicial. A Alan Turing e Marie Curie, pioneiros na ciência de *machine learning* e na física médica, respectivamente, expresso meu sincero agradecimento por terem compartilhado com o mundo conhecimentos técnicos que transformaram minha vida de maneira profunda.

RESUMO

Os exames de mamografia são considerados como padrão-ouro para detecção de câncer de mama, de acordo com a Organização Mundial da Saúde (OMS). Como o exame tem o objetivo de detectar pequenos achados mamográficos, é necessário que os mamógrafos possuam alta sensibilidade e gerem imagens com elevada resolução espacial. Por isso, tais equipamentos são regularmente submetidos a testes de controle de qualidade utilizando objetos simuladores, conforme exigências estabelecidas pela Agência Nacional de Vigilância Sanitária (ANVISA), detalhadas na Resolução da Diretoria Colegiada (RDC) da Instrução Normativa De 27 De Maio De 2021 (IN 92), ou pelo manual da *International Atomic Energy Agency* (IAEA). Nestes testes, artefatos que representam a estrutura de uma mama são imageados em um mamógrafo e, neles, existem estruturas que simulam achados mamográficos, tais como microcalcificações, massas tumorais ou nódulos. Uma quantidade mínima dessas estruturas deve ser visualizada na imagem para garantir a qualidade operacional do equipamento. Atualmente, esta análise é feita de forma visual, o que torna o teste de qualidade subjetivo e operador-dependente. Dessa forma, o presente estudo desenvolveu um modelo baseado em algoritmos de *deep learning* e processamento de imagens a fim de automatizar o controle de qualidade de imagem em equipamentos de mamografia. O modelo desenvolvido atingiu uma acurácia de 96,38%, 96,52% e 94,78% para a classificação de visibilidade das fibras, massas e microcalcificações, respectivamente.

Palavras-chave: mamografia; controle de qualidade; *deep learning*.

ABSTRACT

Mammography exams are considered the gold standard for detecting breast cancer, according to the World Health Organization (WHO). As the objective of the test is to detect small mammographic findings, it is necessary that mammography devices have high sensitivity and generate images with high spatial resolution. Therefore, such equipment is regularly subjected to quality control tests using simulating objects, in accordance with the requirements established by the National Health Surveillance Agency (ANVISA), detailed in the Resolution of the Collegiate Board (RDC) of the Normative Instruction of May 27, 2021 (IN 92), or by the manual of the International Atomic Energy Agency (IAEA). In these tests, artifacts that represent the structure of a breast are imaged in a mammography device and, in them, there are structures that simulate mammographic findings, such as microcalcifications, tumor masses or nodules. A minimum amount of these structures must be visualized in the image to guarantee the operational quality of the equipment. Currently, this analysis is done visually, which makes the quality test subjective and operator-dependent. Thus, the present study developed a model based on deep learning algorithms and image processing in order to automate image quality control in mammography equipment. The model developed reached an accuracy of 96.38%, 96.52% and 94.78% for the classification of fiber visibility, masses and microcalcifications, respectively.

Keywords: *mammography; control quality; deep learning.*

LISTA DE FIGURAS

Figura 1 - Visão esquemática do objeto simulador mamográfico do ACR mostrando as estruturas em suas respectivas posições, onde “F” representam as fibras, “S” as microcalcificações e “M” as massas. Fonte: Lee, Tasi, Shinohara (2010).....	20
Figura 2 - Imagem obtida ao expor o objeto simulador a um feixe de raios X e o software realizar o processamento digital necessário para a visualização das estruturas.	20
Figura 3 - Esquema representativo de uma rede neural artificial. Fonte: Meyer et al. (2018).....	22
Figura 4 - Exemplificação do funcionamento de uma Rede Neural Convolutiva com 10 outputs a serem preditos. Fonte: Hope et al., (2017).	24
Figura 5 - Exemplos de distribuição de histogramas para cada categoria de imagem: imagens escuras e claras, e imagens com baixo e alto contraste. Fonte: Gonzalez et al. (2002)	27
Figura 6 - Exemplo da definição do kernel gaussiano. (a) Distribuição gaussiana com $\sigma = 1$. (b) Kernel 3x3 resultante da distribuição gaussiana. Fonte: Gonzalez et al. (2002).	29
Figura 7 - Exemplos de kernels laplacianos. Fonte: Gonzalez et al. (2002).....	30
Figura 8 - Aplicação da técnica de erosão. (a) Imagem original. (b) Imagem processada. Fonte: Gonzalez et al. (2002).	31
Figura 9 - Processo de dilatação. (a) Imagem Original. (b) Imagem processada. (c) Elemento estruturante. Fonte: Gonzalez et al. (2002).....	31
Figura 10 - Processos de morfologia aplicados a uma imagem. (a) Imagem Original. (b) Imagem ao aplicar erosão. (c) Imagem ao aplicar abertura da Figura 12(b). (d) Imagem ao aplicar dilatação da Figura 12(c). (e) Imagem ao aplicar o fechamento da Figura 12(e). Fonte: Gonzalez et al. (2002).	32
Figura 11 - Fluxograma da metodologia geral utilizada no presente trabalho.....	41
Figura 12 - Representação do procedimento de VOI LUT (a) Antes de aplicar o VOI LUT. (b) Após aplicar o VOI LUT	43
Figura 13 - Diagrama da metodologia de recorte. (a) Imagem com a região especificada para realizar o primeiro recorte. (b) Resultado do primeiro recorte. (c) Imagem com a região especificada para realizar o segundo recorte. (d) Resultado do segundo recorte. (e) Imagem antes de ser rotacionada. (f) Imagem após ser rotacionada. (g) Região especificada para o terceiro recorte. (h) Resultado do terceiro recorte.	44
Figura 14 - Comparação entre as imagens com ângulos de posicionamento. (a) Imagem na posição correta. (b) Imagem na posição incorreta.....	46
Figura 15 - Etapas de processamento de imagem para realizar a rotação. (a) Imagem na posição incorreta. (b) Imagem filtrada com o filtro gaussiano. (c) Kernel de uma circunferência utilizado. (d) Imagem após aplicar a técnica de morfologia com o kernel apresentado anteriormente. (e) Imagem, após aplicar a morfologia, binarizada. (f) Massa 1 detectada. (g) Imagem rotacionada na posição correta.	47
Figura 16 - Exemplo de seleção de coordenadas do terceiro recorte. A Figura (a) ilustra, em azul, o vetor central selecionado para análise. A Figura (b) apresenta o gráfico de intensidade de pixels em relação a posição deste vetor. As linhas em vermelho indicam,.....	48
Figura 17 - Representação do processo de recorte das massas. A circunferência vermelha representa qual estrutura das massas foi recortada. (a) Imagem original.	

(b) Recorte da massa. (b) Aplicada a técnica de equalização de histograma na imagem recortada.....	51
Figura 18 – Representação do processo de recorte das fibras. A circunferência vermelha representa qual estrutura das fibras foi recortada. (a) Imagem original. (b) Recorte da fibra. (b) Aplicada a técnica de equalização de histograma na imagem recortada.....	52
Figura 19 - Representação do processo de recorte das microcalcificações. A circunferência vermelha representa qual estrutura das microcalcificações foi recortada. (a) Imagem original. (b) Recorte da microcalcificação. (b) Aplicada a técnica de filtro derivativo de segunda ordem e filtro gaussiano.....	53
Figura 20 - Retirado de Silva Neto (2020).....	55
Figura 21 - Exemplificação do funcionamento da metodologia de validação cruzada com K-Fold.....	56
Figura 22 - Exemplo das massas recortadas de uma imagem. (a) Massa 1 (b) Massa 2 (c) Massa 3 (d) Massa 4 (e) Massa 5.....	60
Figura 23 - Exemplo das fibras recortadas de uma imagem. (a) Fibra 1 (b) Fibra 2 (c) Fibra 3 (d) Fibra 4 (e) Fibra 5 (f) Fibra 6.....	61
Figura 24 - Exemplo das microcalcificações recortadas de uma imagem. (a) Microcalcificação 1 (b) Microcalcificação 2 (c) Microcalcificação 3 (d) Microcalcificação 4. (e) Microcalcificação 5.....	62
Figura 25 - Diagrama de fluxo do treinamento dos modelos.....	64
Figura 26 - Curvas de aprendizado do modelo de fibras para cada grupo.....	67
Figura 27 - Curvas de aprendizado do modelo de massas para cada grupo.....	68
Figura 28 - Curvas de aprendizado do modelo de microcalcificações para cada grupo.....	69
Figura 29 - Curvas de aprendizado do modelo treinado para as massas. (a) Curva da loss. (b) Curva da acurácia.....	71
Figura 1 - Curvas de aprendizado do modelo treinado para as microcalcificações. (a) Curva da loss. (b) Curva da acurácia.....	71
Figura 32 - Curva ROC AUC para cada classe de estruturas.....	72
Figura 33 - Distribuição de predições comparadas a classificação real das massas.....	73
Figura 34 - Distribuição de predições comparadas a classificação real das fibras.....	73
Figura 35 - Distribuição de predições comparadas a classificação real das microcalcificações.....	73

LISTA DE TABELAS

Tabela 1 - Tabela apresentando os critérios de inclusão e exclusão da revisão integrativa realizada	34
Tabela 2 - Análise e categorização dos artigos selecionados.....	34
Tabela 3 - Tabela com os valores atribuídos para cada função no primeiro recorte.	57
Tabela 4 - Fatores utilizados para as respectivas massas.....	59
Tabela 5 - Fatores utilizados para as respectivas fibras.....	60
Tabela 6 - Fatores utilizados para as respectivas microcalcificações	61
Tabela 7 - Números totais de imagens para cada estrutura, separado por visíveis e não visíveis	62
Tabela 8 – Número de imagens para cada estrutura, fase e classificação.....	63
Tabela 9 - Valores dos pesos atribuídos para cada classe em cada imagem.....	65
Tabela 10 - Resultados com diferentes redes pré-treinadas para as fibras.....	65
Tabela 11 - Resultados com diferentes redes pré-treinadas para as massas.....	66
Tabela 12 - Resultados com diferentes redes pré-treinadas para as microcalcificações.....	66
Tabela 13 – Resultados médios de cada grupo para cada modelo treinado de cada estrutura	70
Tabela 14 - Resultados com os dados de teste	72
Tabela 15 - Resultados obtidos por (a) Sundell et al., (2019), (b) Sundell et al., (2022) e, (c) metodologia proposta, avaliados por (1) profissionais e (2) método automatizado	74
Tabela 16 - Comparação de acurácia da metodologia proposta com o de outros estudos	75
Tabela 17 - Resultados comparados com os de Sundell et al., (2022).....	76

LISTA DE ABREVIATURAS E SIGLAS

ACR	<i>American College of Radiology</i>
ANVISA	Agência Nacional de Vigilância Sanitária
AUC	<i>Area Under the Curve</i>
CBR	Colégio Brasileiro de Radiologia
CEP	Comitê de Ética em Pesquisa
CNN	<i>Convolutional Neural Networks</i>
DICOM	<i>Digital Imaging Communications in Medicine</i>
DWT	<i>Discrete Wavelet Transform</i>
HCPA	Hospital de Clínicas de Porto Alegre
IN	Instrução Normativa
MLP	<i>Multi-Layer Perceptron</i>
PCA	<i>Principal Component Analysis</i>
R1	Primeiro Recorte
R2	Segundo Recorte
R3	Terceiro Recorte
RGB	<i>Red, Green, Blue</i>
ROC	Receiver-Operating-Characteristic
ROI	<i>Region-Of-Interest</i>
SR	Segundo Recorte
SVM	<i>Support Vector Machine</i>
UFCSPA	Universidade Federal de Ciências da Saúde de Porto Alegre

SUMÁRIO

1 INTRODUÇÃO.....	16
2 OBJETIVOS.....	19
2.1 OBJETIVO GERAL.....	19
2.2 OBJETIVOS ESPECÍFICOS.....	19
3 FUNDAMENTAÇÃO TEÓRICA	19
3.1 O TESTE DE CONTROLE DE QUALIDADE DE IMAGEM.....	19
3.2 DEEP LEARNING.....	21
3.3 <i>PROCESSAMENTO DE IMAGENS</i>	25
3.3.1 EQUALIZAÇÃO DE HISTOGRAMA.....	26
3.3.2 FILTROS.....	28
3.3.3 MORFOLOGIA MATEMÁTICA	30
3.3.3.1 EROSÃO.....	30
3.3.3.2 DILATAÇÃO.....	31
3.3.3.3 ABERTURA E FECHAMENTO.....	32
4 REVISÃO DA LITERATURA.....	32
4.1 METODOLOGIA PROPOSTA POR ÁLVAREZ ET AL. (2012).....	35
4.2 METODOLOGIA PROPOSTA POR DE <i>ASAHARA E KODERA (2012)</i>	36
4.3 METODOLOGIA PROPOSTA POR DE SUNDEL <i>ET AL.</i> (2019).....	37
4.4 METODOLOGIA PROPOSTA POR DE HO, HWANG e T SAI (2022).....	38
4.5 METODOLOGIA PROPOSTA POR DE SUNDEL ET AL. (2022).....	39
5 METODOLOGIA.....	40
5.1 GERAÇÃO DO BANCO DE DADOS.....	41
5.2 APLICAÇÃO DO <i>VOI LUT</i>	42
5.3 PRÉ-PROCESSAMENTO DAS IMAGENS.....	44
5.4 RECORTE DAS ESTRUTURAS.....	49
5.4.1 RECORTE DAS MASSAS.....	50
5.4.2 RECORTE DAS FIBRAS.....	51
5.4.3 SEGMENTAÇÃO DAS MICROCALCIFICAÇÕES.....	52
5.5 TREINAMENTO DOS MODELOS DE <i>DEEP LEARNING</i>	53

5.5.1 ORGANIZAÇÃO DOS CONJUNTOS DE DADOS PARA TREINO, VALIDAÇÃO E TESTE	53
5.5.2 DEFINIÇÃO DA ARQUITETURA DOS MODELOS	53
5.5.3 AVALIAÇÃO DA PERFORMANCE DOS MODELOS.....	54
5.5.4 APLICAÇÃO DA TÉCNICA DE VALIDAÇÃO CRUZADA K-FOLD	56
5.5.5 REALIZAÇÃO DO TREINAMENTO FINAL	56
6 DISCUSSÃO DOS RESULTADOS	57
6.1 RESULTADOS DO R1 E R2	57
6.2 RESULTADOS DO ROTAÇÃO DAS IMAGENS	57
6.3 RESULTADOS DO R3	58
6.4 RESULTADOS DO RECORTE DAS ESTRUTURAS	59
6.5 SEGREGAÇÃO DAS IMAGENS	62
6.6 TREINAMENTO E RESULTADO DOS MODELOS	63
6.6.1 SELEÇÃO DA REDE PRÉ-TREINADA	63
6.6.2 RESULTADOS DA VALIDAÇÃO CRUZADA	66
6.6.3 RESULTADOS COM OS DADOS DE TESTE	70
7 DESENVOLVIMENTO FUTURO.....	77
7.1 RECONSTRUÇÃO DA IMAGEM E ANÁLISE DE CONFORMIDADE	77
7.2 DESENVOLVIMENTO DO <i>FRAMEWORK</i>	77
8 CONCLUSÃO.....	77
REFERÊNCIAS	80
ANEXO	87

1 INTRODUÇÃO

O câncer de mama é a principal doença incidente e com maior taxa de mortalidade em mulheres no mundo (WORLD HEALTH ORGANIZATION, 2021). O Instituto Nacional de Câncer (INCA) relatou cerca de 66.000 novos casos de câncer de mama em 2021, dos quais, cerca de 18.000 estavam presentes em mulheres que vieram a óbito (INSTITUTO NACIONAL DE CÂNCER, 2021). Para diminuir a morbidade e a mortalidade decorrente dessa neoplasia, sua detecção precoce é fundamental, a qual é feita, em grande parte, via mamografia, exame de diagnóstico que utiliza raios X de baixa energia em um equipamento denominado mamógrafo. Neste exame, a mama é comprimida até uma certa intensidade, com o intuito de expor toda a região do parênquima mamário a fim de garantir a melhor visualização da região anatômica. A mamografia é recomendada pela Organização Mundial da Saúde, orientação seguida, também, por vários países (INSTITUTO NACIONAL DE CÂNCER, 2021), pois é capaz de identificar alterações suspeitas de câncer antes mesmo do surgimento dos sintomas, ou seja, antes que seja palpada qualquer alteração das mamas (INSTITUTO NACIONAL DE CÂNCER, 2020).

Para garantir um diagnóstico correto, o mamógrafo deve fornecer condições operacionais que garantam imagens com visibilidade de baixo contraste, alta resolução espacial e amplo alcance dinâmico (SUNDELL et al., 2019). Para atingir esses requisitos, o mamógrafo deve ser submetido periodicamente aos testes de qualidade, devendo, no Brasil, estar de acordo com as conformidades estipuladas pela Agência Nacional de Vigilância Sanitária (ANVISA), detalhadas na Resolução da Diretoria Colegiada (RDC) N° 611 IN 92 (“INSTRUÇÃO NORMATIVA - IN N° 92, DE 27 DE MAIO DE 2021”, 2021), e no manual da *International Atomic Energy Agency* (IAEA) (Quality Assurance Programme for Digital Mammography, 2011).

Existem diversos testes obrigatórios a serem realizados para assegurar o controle de qualidade dos equipamentos. No que contempla o teste de qualidade de imagem, utiliza-se um objeto simulador, como o da *American College of Radiology* (ACR) ou do Colégio Brasileiro de Radiologia (CBR), na qual a escolha de qual utilizar é do próprio serviço (BARRAGAN, 2016). Neles existem estruturas que simulam achados anormais de uma mama, como fibras, microcalcificações e massas tumorais características, as quais devem ser identificadas nas imagens para garantir a qualidade do equipamento. O contraste e/ou tamanho dessas diferentes estruturas decaem progressivamente, ordenadas da mais visível para a menos visível (CHEN et

al., 2016). Com a visibilidade das estruturas, cabe ao operador do teste de qualidade analisar visualmente quantas estruturas estão presentes na imagem. Essa visualização é subjetiva (BARRAGAN, 2016; BROOKS; TRUEBLOOD; KEARFOTT, 1994), pois depende da percepção do operador do teste.

A necessidade de recursos automáticos auxiliares no controle de qualidade de equipamentos de radiodiagnóstico é evidente uma vez que os métodos convencionais são subjetivos e dependem da percepção do profissional responsável pela análise. *Graber et al. (2005)* avaliou a contribuição de componentes cognitivos para as imprecisões de diagnóstico. Seus resultados apontam que tais componentes contribuíram em 74% dos casos nos quais as imprecisões de diagnóstico estavam presentes, sendo as causas mais comuns a avaliação incorreta da relevância dos achados, a percepção defeituosa e imprecisões decorrentes do uso de heurísticas por parte do profissional. *Odgie et al. (2012)* constatou que erros de diagnóstico estão relacionados a, pelo menos, um viés cognitivo. Dessa forma, ressalta-se a importância do desenvolvimento de um sistema que independe do operador.

Estudos com resultados promissores implementaram técnicas de processamento digital a imagens de objetos simuladores, bem como análises estatísticas de parâmetros de equipamentos de mamografia, com o objetivo de melhorar a visualização da imagem e automatizar as análises de qualidade (SUNDELL, 2019; BARRAGAN, 2016; ALVAREZ, 2012; HO, HWANG, AND TSAI, 2022). Dentre os trabalhos, destaca-se o método de *Sundell et al. (2019)*, que utilizou filtros *wavelets* e análise multirresolução para avaliar a qualidade de imagens em testes de qualidade de mamógrafos, utilizando o objeto simulador do ACR. Os resultados obtidos na capacidade de visualização dos objetos nas imagens do objeto simulador com o sistema automatizado foram comparados com os resultados obtidos na visualização das imagens de quatro profissionais. No caso das fibras, ambas as formas de análise levaram a avaliações acerca do número de fibras visíveis equiparáveis. Já no caso das microcalcificações e das massas, o método obteve resultados superiores.

Barragan et al. (2016) estudou a automatização da detecção de estruturas do objeto simulador do CBR. Neste trabalho, foram realizados recortes ao redor das estruturas obtidas nas imagens, ou seja, ROIs (em inglês, *regions-of-interest*), e aplicadas técnicas de processamento, segmentação e operadores morfológicos. Os resultados do sistema automatizado foram comparados aos resultados obtidos

visualmente. O método teve resultados superiores comparados com a análise visual pelos operadores do controle de teste, diminuindo a subjetividade do teste de qualidade de imagem realizado por humanos.

Um aspecto fundamental para ser levado em conta em um método automatizado de controle de qualidade da imagem, é que esta deve ser compatível com a capacidade humana de visualização tendo em vista que os exames gerados pelos equipamentos serão avaliados visualmente por um profissional de saúde. Entretanto, é comum que apenas a aplicação de métodos embasados em técnicas de processamento digital de imagem promova melhorias na imagem e que, conseqüentemente, a detecção das estruturas do objeto simulador seja superior ao que seria resultante de uma análise visual, conforme os resultados dos trabalhos previamente apresentados. Nesse sentido, a combinação destas técnicas com *machine learning* pode ter um potencial solução para este problema, pois os modelos podem ser treinados levando em conta a visibilidade das estruturas das imagens por parte dos especialistas do serviço (isto é, os relatórios do especialista podem ser utilizados como informações de saída para treinamento do modelo).

Técnicas de *deep learning* vêm sendo cada vez mais utilizadas para promover apoio ao diagnóstico clínico através da análise de imagens médicas. Estas técnicas se baseiam na construção de algoritmos para predição e tomada de decisões, a partir de um volume massivo de dados. Estudos recentes reforçam a eficácia dessa técnica nos mais diversos campos de aplicação (KHAN, 2019; MAGHDID, 2021; GAO, 2020; MA, 2019). Dentre os trabalhos na área, destacam-se aqueles que utilizam redes neurais convolucionais pré-treinadas para extração de características das imagens, como em *Abdolali et al. (2020)*, *Liu et al. (2019)* ou *Ma et al. (2017)*. Embora a utilização de técnicas de *deep learning* venha sendo explorada com sucesso como ferramenta auxiliar ao diagnóstico clínico, a literatura carece da utilização deste tipo de método no contexto de controle de qualidade de equipamentos.

Assim, o presente estudo tem como objetivo geral de desenvolver um método computacional para análise de imagens de simuladores de mama da ACR baseado em técnicas de processamento digital de imagens combinadas a técnicas de *deep learning* para o controle de qualidade de imagem em mamógrafos a fim de responder a seguinte questão norteadora: “Qual seria o diferencial quantitativo da aplicação de algoritmos de *deep learning* no contexto do problema proposto, em relação às metodologias atuais da literatura?”.

Neste capítulo uma introdução ao tema é apresentada, no capítulo 2, os objetivos e justificativa do estudo. No capítulo 3 apresenta a fundamentação teórica, abordando teorias relevantes para a compreensão do presente projeto. A capítulo 4 apresenta uma revisão na literatura acerca de estudos semelhantes com o presente projeto. No capítulo 5, os métodos e materiais. Os resultados e são apresentados no capítulo 6. Não capítulo sete alguns pontos para desenvolvimento no futuro, e a conclusão do presente estudo no capítulo 8.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Desenvolver um método computacional de análise de imagens para objetos simuladores da ACR utilizando técnicas de processamento digital de imagens combinadas a algoritmos de *deep learning* para o controle de qualidade de imagem em mamógrafos.

2.2 OBJETIVOS ESPECÍFICOS

- Criar um banco de dados contendo imagens de um objeto simulador geradas rotineiramente pelo Hospital de Clínicas de Porto Alegre (HCPA) e novas imagens de objetos simuladores geradas especificamente para o projeto, as quais devem simular problemas operacionais;
- Selecionar e aprimorar métodos existentes na literatura para o processamento digital de imagens;
- Definição de arquitetura de redes neurais convolucionais para a aplicação de algoritmos de *deep learning*;
- Avaliar a visibilidade das estruturas nas imagens do simulador da ACR utilizando técnicas de *deep learning*.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 O TESTE DE CONTROLE DE QUALIDADE DE IMAGEM

O teste de controle de qualidade da imagem tem o objetivo de avaliar a qualidade da imagem produzida pelo equipamento de mamografia, analisando a visibilidade de estruturas que simulam anormalidades em uma mama. Ele é realizado através do imageamento de um objeto simulador no mamógrafo. O objeto que será utilizado para

o desenvolvimento do presente projeto será o modelo RMI 156 da *American College of Radiology* (ACR) ilustrado na Figura 1, o qual representa uma mama de 4,5 cm de espessura, composta por 50% de tecido adiposo e 50% de tecido glandular (LEE; TSAI; SHINOHARA, 2010). O objeto contém seis fibras com 1,56 mm (F1), 1,12 mm (F2), 0,89 mm (F3), 0,75 mm (F4), 0,54 mm (F5) e 0,40 mm (F6) de espessura; cinco grupos de microcalcificações com diâmetros de 0,54 mm (S1), 0,40 mm (S2), 0,32 mm (S3), 0,24 mm (S4) e 0,16 mm (S5) e cinco massas com diâmetros de 2 mm (M1), 1 mm (M2), 0,75 mm (M3), 0,50 mm (M4) e 0,25 mm (M5) (LEE; TSAI; SHINOHARA, 2010).




Figura 1 - Visão esquemática do objeto simulador mamográfico do ACR mostrando as estruturas em suas respectivas posições, onde "F" representam as fibras, "S" as microcalcificações e "M" as massas. **Fonte:** Lee, Tasi, Shinohara (2010).

Para a obtenção da imagem, o objeto simulador, ou *phantom*, é posicionado no equipamento de mamografia, comprimido e exposto a um feixe de raios X, obtendo a imagem especificada na Figura 2.




Figura 2 - Imagem obtida ao expor o objeto simulador a um feixe de raios X e o software realizar o processamento digital necessário para a visualização das estruturas.

De acordo com o simulador da ACR, para que uma imagem seja classificada como conforme, é necessário que as quatro fibras com maiores espessuras, as três maiores microcalcificações e as três maiores massas sejam visíveis (LEE; TSAI; SHINOHARA, 2010). Já, de acordo com a RDC 611 IN 92, é especificado que a última fibra visível deve ter espessura de 0,75 mm, ou menor; a última microcalcificação visível deve ter diâmetro de 0,32 mm, ou menor; e a última massa visível deve ter diâmetro de 0,75 mm, ou menor. Os dois critérios de conformidade são aceitos pela ANVISA. Todo esse processo de contagem é realizado de forma visual pelo profissional capacitado, com periodicidade diária, conforme especificação na Instrução Normativa 92 da ANVISA (“INSTRUÇÃO NORMATIVA - IN Nº 92, DE 27 DE MAIO DE 2021”, 2021). Com um monitor específico de alta resolução, a imagem do *phantom* é obtida, e o profissional é responsável por realizar a contagem do número de massas, fibras e microcalcificações visíveis. Essa visualização e contagem depende da capacidade visual do profissional, bem como sua experiência na realização do teste.

As imagens são usualmente fornecidas no formato DICOM (*Digital Imaging Communications in Medicine*), o qual é composto pela matriz da imagem, e, também, por elementos que a identificam como uma imagem médica (SAMPAIO, 1999). As informações armazenadas utilizam identificadores únicos para uma informação de elemento composto por um par ordenado de números (um número de grupo seguido por um número de elemento), dos quais são utilizados para identificar atributos e seus elementos de dados correspondentes (NEMA, 2016), conhecidos como *tags*, que estruturam esse formato de armazenamento (MACIEL, 2016).

Dentre as diversas informações apresentadas no arquivo DICOM, alguns parâmetros podem auxiliar no controle de qualidade em mamografia, uma vez que este formato armazena informações da aquisição da imagem como, produto corrente-tempo (*mAs*), quilo voltagem pico (*kVp*), dose na entrada da pele (*DEP*), dose glandular média (*DGM*) e tempo de exposição (CAVALCANTE, 2019).

3.2 DEEP LEARNING

O uso de algoritmos de *deep learning* para análise de imagens surge como uma alternativa promissora para o auxílio de controle de qualidade de imagem de uma maneira automatizada. Esses algoritmos são uma série de modelos matemáticos compostos por múltiplas camadas de processamento de dados, com o objetivo

aprender formas de representações de dados com múltiplos níveis de abstrações (LECUN *et al.*, 2015). As técnicas de *deep learning* têm sido cada vez mais exploradas como um recurso de apoio à decisão, principalmente para auxiliar especialistas em análises de imagens. Sua aplicação em imagens médicas é provavelmente o domínio mais adequado da área (CASTIGLIONI *et al.*, 2021). Diversos estudos, portanto, trazem resultados promissores utilizando técnicas de *deep learning* no auxílio do diagnóstico médico, a partir de imagens.

Para uma melhor compreensão de técnicas de *deep learning*, deve-se introduzir o funcionamento de uma rede neural artificial. Portanto, de acordo com LOPES (2017), redes neurais artificiais são modelos matemáticos de inspiração biológica que, através de combinações de unidades computacionais simples chamadas neurônios, buscam estimar ou aproximar o valor de funções. Como apresentado anteriormente, a primeira rede neural desenvolvida foi em 1958, por Warren McCulloch e Walter Pitts, denominada *Perceptron*, que tem um funcionamento muito simples, com apenas um neurônio e uma camada, dando apenas uma resposta binária (LOPES, 2017). A Figura 3 representa esquematicamente o funcionamento de um neurônio em uma rede neural artificial.

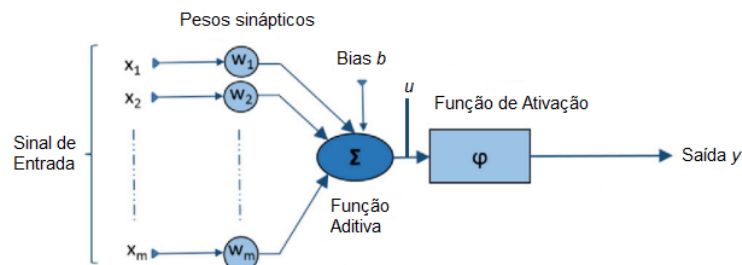


Figura 3 - Esquema representativo de uma rede neural artificial. **Fonte:** Meyer et al. (2018)

Com isso, um neurônio é uma unidade de processamento de informações que é fundamental para o funcionamento de uma rede neural (HAYKIN, 2010).

Analisando a Figura 3, é possível identificar alguns elementos básicos de um modelo de um neurônio:

- Dados de entrada do neurônio. De maneira geral, cada entrada x_j é multiplicada por um valor denominado de peso sináptico w_j .
- Uma função aditiva, que tem como função somar todos os sinais de entrada, após terem passado pela etapa de ponderação com seus respectivos pesos x_j .

- Operador externo *bias*. Ele tem o efeito de deslocar para cima (*bias* positivo) ou para baixo (*bias* negativo) a entrada da função de ativação.
- Uma função de ativação, que introduz uma componente não linear nas redes neurais, que faz com que elas possam aprender mais do que relações lineares entre as variáveis de entrada e saída.
- Saída w_j , que dará a classe na qual aquele sinal foi classificado, ou a probabilidade de ele pertencer a tal classe.

Matematicamente, é possível descrever o neurônio k apresentado na Figura 3 em um par de equações:

$$u = b + \sum_{j=1}^m w_j x_j, \quad (1)$$

e

$$y = \varphi(u), \quad (2)$$

em que u é a saída da combinação linear devido aos sinais de entrada; b é o *bias*; φ é a função de ativação; e y é o sinal de saída do neurônio.

De maneira geral, o aprendizado supervisionado é um problema de otimização, cujo objetivo é minimizar as diferenças entre as saídas previstas pela rede e as saídas medidas. Os parâmetros de ajuste são os pesos w_j e o *bias* de cada neurônio. O processo de ajuste dos parâmetros é denominado treinamento do modelo. Ele é realizado a partir de um conjunto de dados cujas entradas e saídas são conhecidas (dados de treino).

Os avanços tecnológicos viabilizaram a obtenção de computadores com capacidade de processamento cada vez mais elevada e de custo acessível. Com isso, muitas tecnologias surgiram inspiradas nas redes neurais. Dentre elas, as redes neurais convolucionais (CNNs) correspondem à uma categoria de algoritmos que utilizam a técnica de convolução em pelo menos uma de suas camadas (ARAÚJO, 2017). Sua principal aplicação é para reconhecimento de padrões em imagens, ou seja, extração de *features*. Essencialmente, as CNNs são compostas por três tipos de camadas: camadas convolucionais, camadas de *pooling*, responsáveis pela redução dimensional dos dados, e camadas totalmente conectadas, que são, basicamente, redes neurais artificiais.

As camadas convolucionais são compostas por um conjunto de filtros que recebem como entrada as imagens na forma de um arranjo de matrizes bidimensionais ou tridimensionais. Durante o treinamento da CNN, esses filtros são ajustados com o intuito de gerar novos atributos capazes de enfatizar as características relevantes, identificadas a partir do volume de entrada (ARAÚJO, 2017). Os novos atributos alimentam as camadas de *pooling*, as quais têm como objetivo reduzir progressivamente a dimensão espacial de entrada, que, conseqüentemente, reduz o esforço computacional da rede e evita o *overfitting* (ARAÚJO, 2017) (isto é, ajuste excessivo em relação aos dados de treinamento, porém ineficiente para prever outros dados similares). O princípio dessa operação é, a partir de uma entrada na camada de *pooling*, e com uma janela de operação com um tamanho fixo, dar como saída uma nova matriz de dimensão reduzida, gerada a partir do cálculo de um valor obtido a partir dos elementos das partes da matriz original selecionada de acordo com o tamanho da janela de operação *GlobalMaxPooling*. No caso deste trabalho, utilizou-se o *MaxPooling*, que corresponde ao valor máximo da janela. A Figura 4 exemplifica o que foi descrito acima.




Figura 4 - Exemplificação do funcionamento de uma Rede Neural Convolucional com 10 outputs a serem preditos. **Fonte:** Hope *et al.*, (2017).

Dessa forma, os atributos com dimensionalidade reduzida alimentam as camadas totalmente conectadas, que irão promover a classificação das imagens em classes pré-determinadas. As camadas totalmente conectadas são usualmente compostas por redes neurais convencionais *Multi-Layer Perceptron* (MLP), retornando como resposta a probabilidade de a imagem analisada pertencer a cada uma das classes pré-determinadas (ARAÚJO, 2017).

De forma similar ao que já foi descrito, o ajuste dos parâmetros é feito por otimização com os dados de treino. Dessa forma, a quantidade desses parâmetros de

ajustes em CNNs é extremamente elevada e, por isso, são necessários grandes bancos de dados para gerar modelos confiáveis. Como na maioria dos casos reais os bancos de dados de imagens possuem limitações, uma prática comum é a utilização de modelos pré-treinados.

As CNNs pré-treinadas são modelos treinados previamente com um grande conjunto de dados, o qual não necessariamente tem correlação com o tipo de imagem a ser avaliada pelo usuário. Ou seja, se o conjunto de dados for volumoso e genérico o suficiente, as características aprendidas pela CNN pré-treinada podem atuar como um modelo genérico do mundo visual. Portanto, suas características podem ser úteis para muitos problemas de visão computacional, mesmo que esses novos problemas possam envolver classes completamente diferentes daquelas da tarefa original (CHOLLET *et al.*, 2018). Normalmente, essas CNNs são treinadas com o conjunto de dados *ImageNet* (CHOLLET *et al.*, 2018, DENG *et al.*, 2009), que contém, atualmente, mais de 14 milhões de imagens de diversas categorias. Alguns exemplos de CNNs pré-treinadas são a *Xception* (CHOLLET *et al.*, 2018), VGG (SIMONYAN; ZISSEMAN, 2015), *ResNet* (HE *et al.*, 2015), *InceptionV3* (SZEGEDY *et al.*, 2015), *MobileNet* (HOWARD *et al.*, 2017), *DenseNet* (HUANG *et al.*, 2018), *EfficientNet* (TAN; LE, 2020) e entre outros. Uma das aplicações mais convenientes de redes pré-treinadas é a extração de características, uma técnica que envolve o uso de representações aprendidas por um modelo em um treinamento anterior, que, no caso do presente estudo, são CNNs pré-treinadas, denominadas de base convolucional (CHOLLET *et al.*, 2018). Extrair essas características adiciona um grande potencial para o aprendizado das camadas totalmente conectadas. Esse método pode ter suma importância no auxílio de classificação de imagens de objetos simuladores em equipamentos de imagens médicas.

3.3 PROCESSAMENTO DE IMAGENS

Uma imagem se trata de uma matriz, cujos valores são denominados *pixels*. Cada valor de *pixel* é correlacionado à intensidade de cor do canal correspondente. Existem as imagens com três canais, RGB, (do inglês, Red, Green and Blue) e com um canal, estando essas imagens de um canal na escala de tons de cinza. Imagem com três canais estão distribuídas nos três espectros de cor, vermelho, verde e azul, sendo que a combinação dos canais representa as imagens coloridas. Já nas imagens

de escala cinza, temos apenas um canal, em que, por exemplo, o valor de intensidade zero representa o preto, e o valor de intensidade igual a um, que representa o branco. (GONZALEZ et al., 2002). Muitas vezes, tais imagens podem não ter boa qualidade, sendo necessária a utilização de técnicas de processamento, a fim de melhorar sua respectiva qualidade e auxiliar em treinamentos de modelos de *deep learning*, por exemplo. Entretanto, tais técnicas não são utilizadas apenas para melhorar a qualidade de imagens, mas também em casos na qual é necessário adequá-la para a necessidade de cada problema. Por exemplo, em casos de recorte, extração ou destaque de estruturas específicas da imagem, rotações etc. A seguir, as técnicas de processamento de imagens utilizadas neste trabalho serão apresentadas.

3.3.1 EQUALIZAÇÃO DE HISTOGRAMA

É possível avaliar a distribuição dos *pixels* de uma imagem através de um histograma, em que o eixo *y* é o número de ocorrências do respectivo valor de *pixel*, e o eixo *x* o valor do *pixel*. O formato do histograma está correlacionado à aparência da imagem (GONZALEZ et al., 2002). Imagens mais escuras tendem a ter suas barras de contagem de intensidade de *pixels* mais localizadas para a esquerda, próximas de zero, ou seja, da cor preta. Já as claras, tendem a estar mais localizadas para a direita, próximo do número um, ou seja, branco. Nas imagens com baixo contraste, as barras do histograma se distribuem na sua região central. Naquelas com alto contraste, o histograma cobre quase todos os valores disponíveis do eixo *x*. A Figura 5 demonstra esse comportamento.

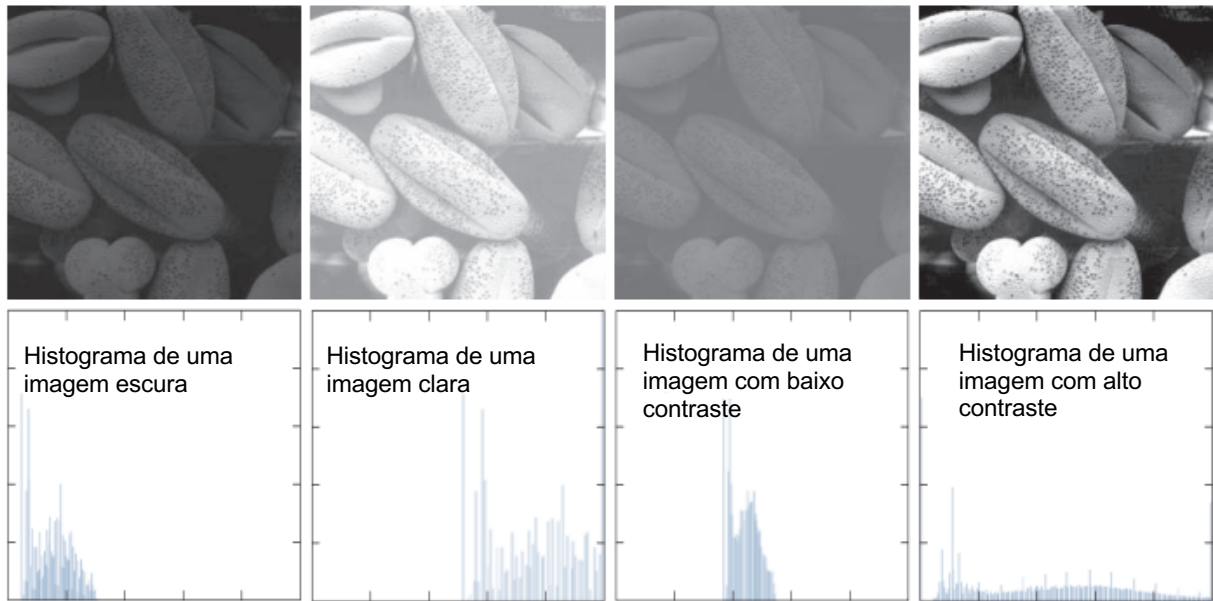


Figura 5 - Exemplos de distribuição de histogramas para cada categoria de imagem: imagens escuras e claras, e imagens com baixo e alto contraste. **Fonte:** Gonzalez *et al.* (2002)

Conforme ilustrado na Figura 5, para garantir um melhor destaque de detalhes em uma imagem, o ideal é que ela possua alto contraste (GONZALEZ et al. 2002). Dessa forma, a equalização do histograma tem o objetivo de expandir o histograma de uma imagem escura, clara ou com baixo contraste, por exemplo, a fim de garantir que ele cubra toda a extensão do das intensidades de *pixels*, melhorando a qualidade da imagem. Ela é aplicada conforme a Equação 3.

$$s_k = T(r_k) = (L - 1) \sum_{j=0}^k p_r(r_j), \quad k = 0, 1, 2, \dots, L - 1, \quad (3)$$

Onde,

$$p_r(r_k) = \frac{n_k}{MN}, \quad (4)$$

A Equação 3 é aplicada para cada valor de pixel da imagem de entrada. Ou seja, o *pixel* da imagem de entrada com intensidade r_k é mapeado em um *pixel* correspondente com nível s_k na imagem de saída. L é o número de níveis de intensidade possíveis na imagem (por exemplo, 256 para imagens de 8-bits). Além disso, p_r é a probabilidade de a ocorrência de uma intensidade de *pixel* r_k , n_k denota o número de *pixels* que tem intensidade r_k , e MN é o número total de *pixels* presente na imagem.

3.3.2 FILTROS

A utilização de filtros no âmbito deste trabalho visa a redução de ruídos nas imagens. Existem, de maneira geral, duas categorias de filtros primitivos: os passa-baixa, e os passa-alta. Eles podem ser aplicados tanto no espectro do espaço, quanto no espectro da frequência. O espectro da frequência de uma imagem é obtido através de sua transformada de *Fourier*. O nome dos filtros “passa-baixa” e “passa-alta” vem da relação com o espectro da frequência: os “passa-alta” removem informações de baixa frequência, já os “passa-baixa”, removem informações de alta-frequência (GONZALEZ et al. 2002). Entretanto, a presente pesquisa abordou apenas aqueles no espectro do espaço. Portanto, os tópicos a serem discutidos estarão limitados dentro desse contexto.

Os filtros passa-baixa, também chamados de *averaging filters*, ou *smoothing spatial filters*, são filtros espaciais que auxiliam a reduzir mudanças abruptas de intensidade de *pixels*. O resultado de sua aplicação é um aspecto “borrado/esfumaçado” na imagem resultante. Dessa forma, a suavização é usada para reduzir detalhes irrelevantes em uma imagem. O termo “*kernel*” se refere a matriz do filtro a ser aplicado. Existem variações de *kernels*. A definição da matriz do filtro irá impactar diretamente na imagem resultante pós-filtragem. Esses *kernels* são utilizados, portanto, em operações de convolução entre eles, e a imagem a ser filtrada. Existem algumas categorias de *kernels* aplicados em filtragem passa-baixa na literatura, como os *box kernels* ou os *kernels* gaussianos. Os *box kernels* são basicamente filtros que aplicam a média em uma certa janela da matriz. Os *kernels* gaussianos são filtros que derivam da distribuição gaussiana, conforme a Equação 5,

$$G(s, t) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{s^2+t^2}{2\sigma^2}}, \quad (5)$$

Em que s e t denotam as coordenadas da primeira e segunda dimensão e σ é o desvio padrão

A Figura 6 um exemplo de como é estimado o *kernel* gaussiano.

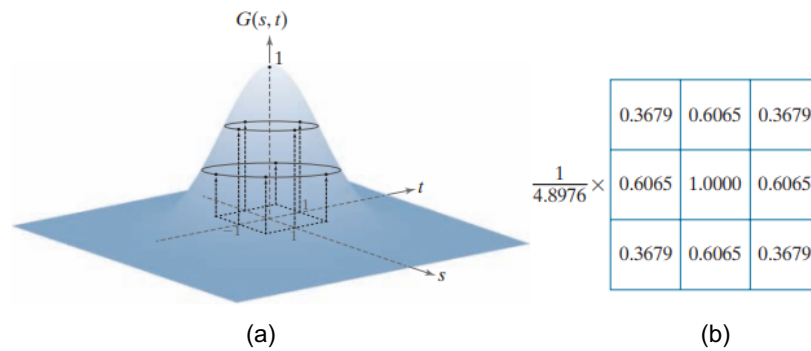


Figura 6 - Exemplo da definição do *kernel* gaussiano. (a) Distribuição gaussiana com $\sigma = 1$. (b) Kernel 3x3 resultante da distribuição gaussiana. **Fonte:** Gonzalez *et al.* (2002).

Contrariamente aos filtros passa-baixa, os filtros passa-alta tendem a destacar as transições de intensidade. Um exemplo é o filtro derivativo de segunda ordem, o qual é em diferenciação, auxiliando no realce de transições de intensidade, detectando mudanças abruptas de intensidade de *pixels*. Para isso, o comportamento dele deve favorecer alguns requerimentos (GONZALEZ et al., 2002).

Um exemplo de filtro derivativo de segunda ordem é o filtro Laplaciano. Ele é regido pela Equação 6, na qual x e y demonstram as linhas e colunas, respectivamente, da imagem.

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}, \quad (6)$$

em que,

$$\frac{\partial^2 f}{\partial x^2} = f(x + 1, y) + f(x - 1, y) - 2f(x, y), \quad (7)$$

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

Dessa forma,

$$\nabla^2 f = f(x + 1, y) + f(x - 1, y) + f(x, y + 1) + f(x, y - 1) - 4f(x, y), \quad (9)$$

O que corresponde a seguinte matriz:

$F(x-1, y+1)$	$F(x, y+1)$	$F(x+1, y+1)$
$F(x-1, y)$	$F(x, y)$	$F(x+1, y)$
$F(x-1, y-1)$	$F(x, y-1)$	$F(x+1, y-1)$

De acordo com a matriz apresentada anteriormente, derivam os seguintes *kernels*, representados na Figura 7.

0	1	0	1	1	1	0	-1	0	-1	-1	-1
1	-4	1	1	-8	1	-1	4	-1	-1	8	-1
0	1	0	1	1	1	0	-1	0	-1	-1	-1

Figura 7 - Exemplos de kernels laplacianos. **Fonte:** Gonzalez *et al.* (2002).

3.3.3 MORFOLOGIA MATEMÁTICA

Técnicas de morfologia matemática são utilizadas quando é necessário destacar, diminuir, remover, corrigir ou detectar elementos com certo formato em uma imagem. Ou seja, operações morfológicas podem ser utilizadas para remover imperfeições na imagem e fornecer informações a respeito da sua forma e estrutura. Para isso, existem quatro técnicas presentes em morfologia: erosão, dilatação, abertura e fechamento. Toda técnica de morfologia se baseia em a imagem a ser processada, e o elemento estruturante, conhecido como *kernel* (GONZALEZ et al., 2002).

Em operações de morfologia, existem dois termos que caracterizam a ação do elemento estruturante sob a imagem a ser processada (GONZALEZ et al., 2002):

- **Fit:** Todos os pixels com intensidade x no elemento estruturante cobrem uma área na imagem também com valores x .
- **Hit:** Qualquer pixel com intensidade x do elemento estruturante cobre um elemento também de intensidade x da imagem.

Dessa forma, o elemento estruturante é utilizado em um processo de convolução sob a imagem a ser processada, resultando em uma imagem final.

3.3.3.1 EROSÃO

Em operações de erosão, o elemento estruturante é posicionado com sua origem em (x, y) e o novo valor do pixel da imagem a ser processada é determinado através da lógica (GONZALEZ et al., 2002):

$$g(x, y) = \begin{cases} s & \text{se } b \text{ hits } f \\ 0, & \text{caso contrário} \end{cases}$$

sendo $g(x,y)$ a imagem processada, s o valor máximo de *pixel* atribuído ao elemento estruturante, b o elemento estruturante e f a imagem a ser processada. A Figura 8 demonstra o resultado de uma aplicação de erosão em uma imagem.




Figura 8 - Aplicação da técnica de erosão. (a) Imagem original. (b) Imagem processada. **Fonte:** Gonzalez *et al.* (2002).

3.3.3.2 DILATAÇÃO

Em operações de dilatação, ocorre o mesmo processo, mas com a seguinte lógica a ser aplicada é (GONZALEZ *et al.*, 2002):

$$g(x,y) = \begin{cases} s & \text{se } b \text{ fits } f \\ 0, & \text{caso contrário} \end{cases}$$

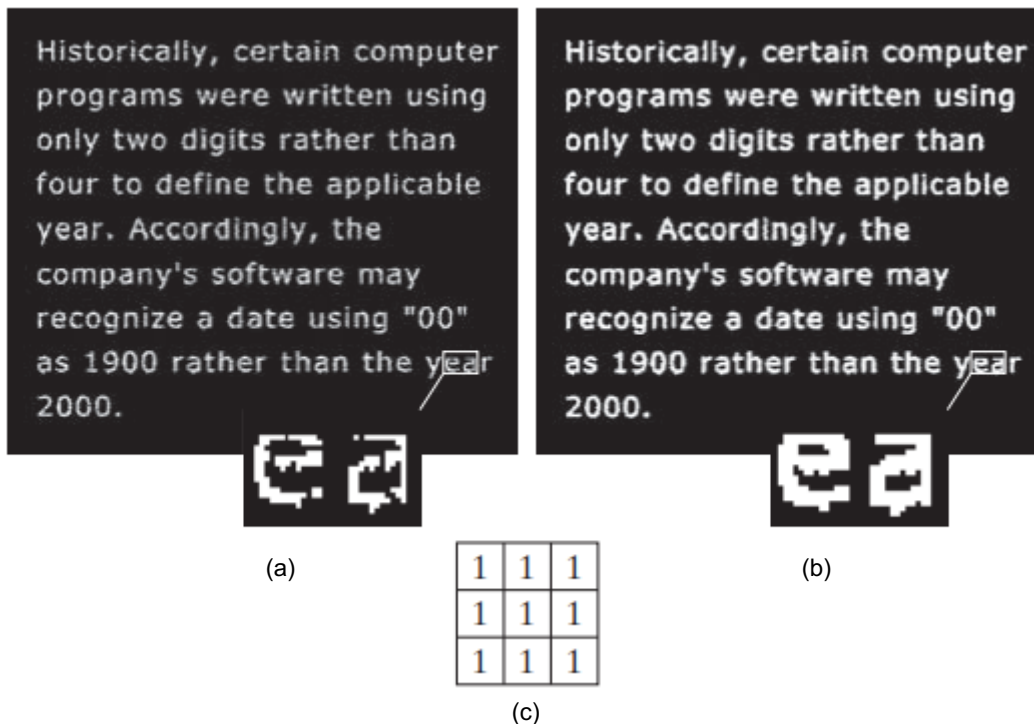


Figura 9 - Processo de dilatação. (a) Imagem Original. (b) Imagem processada. (c) Elemento estruturante. **Fonte:** Gonzalez *et al.* (2002).

3.3.3.3 ABERTURA E FECHAMENTO

Em operações de abertura e fechamento ocorre o mesmo processo, entretanto, para obter a imagem processada, ocorrem duas etapas (GONZALEZ et al., 2002).

- Abertura: erosão seguida por uma dilatação
- Fechamento: dilatação seguida por uma erosão

Pelo fato de a dilatação não ser o inverso de erosão, aplicar um processo após o outro não resultará na imagem original. A Figura 10 demonstra um procedimento de técnicas de morfologia abordando todas as técnicas explicadas anteriormente.




Figura 10 - Processos de morfologia aplicados a uma imagem. (a) Imagem Original. (b) Imagem ao aplicar erosão. (c) Imagem ao aplicar abertura da Figura 12(b). (d) Imagem ao aplicar dilatação da Figura 12(c). (e) Imagem ao aplicar o fechamento da Figura 12(e). **Fonte:** Gonzalez *et al.* (2002).

4 REVISÃO DA LITERATURA

Uma revisão da literatura foi realizada, visando a seleção de artigos para análise. Ela foi realizada seguindo a seguinte metodologia da literatura de uma revisão integrativa, composta por 6 etapas (SOUZA *et al.* 2010):

1. Identificação do problema da pesquisa: questões norteadoras, palavras-chave, equação de busca e bases de busca;
2. Estabelecimento dos critérios de inclusão e exclusão e das bases de busca;
3. Identificação dos estudos pré-selecionados e selecionados;
4. Análise e categorização dos estudos selecionados;
5. Análise e interpretação dos resultados;

6. Escrita do artigo.

De acordo com a metodologia apresentada acima, as questões norteadoras foram:

- 1) *Quais são os métodos mais recentes que estão sendo aplicados para imagens de objetos simuladores de mama, ou parâmetros operacionais?*
- 2) *Quais são os métodos mais recentes que estão sendo aplicados para a análise de controle de qualidade de mamógrafos utilizando imagens de objetos simuladores?*
- 3) *Quais são os dados de entrada desses métodos?*
- 4) *Qual a qualidade dos resultados desses métodos?*

Baseado nas questões norteadoras, os descritores foram: “*automat**”, “*learning*”, “*mammography*”, “*quality assurance*”, “*control quality*”, “*phantom*” e “*image*”. Após a definição das palavras-chave, duas equações de busca foram definidas.: a primeira, *((automat*) OR (learning)) AND (mammography) AND ((quality assurance) OR (control quality)) AND (phantom) AND (image)*; a segunda, *((automate) OR (automatic) OR (learning)) AND (mammography)) AND ((quality assurance) OR (control quality)) AND (phantom) AND (image)*.

Essas *strings* de buscas foram selecionadas para filtrar apenas os artigos que aplicavam, especialmente, métodos computacionais para testes de qualidade de imagem em mamografia, utilizando um objeto simulador. As equações de busca foram aplicadas nas seguintes bases de dados: *PubMed*, *IEEEXplore* e *Science Direct*. Estas são as bases de dados que têm mais estudos publicados na área de tecnologia. A segunda questão de pesquisa foi aplicada na área de *Science Direct Database*, pois foi o único que não aceitou o símbolo “asterisco” na equação de pesquisa. Dessa forma, algumas variações do prefixo “*automat**” (*automation*, *automatic*, *automatically*, dentre outros) foram inseridas manualmente. A segunda etapa foi definir os critérios de inclusão e exclusão de acordo com a Tabela 1.

Tabela 1- Tabela apresentando os critérios de inclusão e exclusão da revisão integrativa realizada

Crítérios de Inclusão	Crítérios de Exclusão
Apenas artigos publicados em periódicos indexados	Artigos em duplicatas
Publicados de 2011 até 2023	Este não é um artigo relacionado a métodos computacionais para controle de qualidade em equipamentos de imageamento médico ou métodos computacionais que impactam diretamente na qualidade da imagem.
Linguagem de português, inglês ou espanhol	Artigos que não utilizam imagens de objetos simuladores
Artigo Original	Artigos que são relacionados a exames de tomossíntese

Ao final da análise dos artigos retornados pelas *strings* de buscas nas bases de dados e na aplicação dos critérios de inclusão e exclusão, restaram-se 8 estudos e eles foram categorizados de acordo com os 4 critérios de classificação dos artigos, as quais estão separadas numericamente em cada coluna na Tabela 2:

- 1) *Tipo de objeto simulador utilizado;*
- 2) *Utiliza técnicas de processamento digital de imagens?*
- 3) *A abordagem é sobre um método que auxilia o controle de qualidade de imagem?*
- 4) *Utiliza parâmetros operacionais como dados de entrada, além da imagem?*

A Tabela 2 apresenta um resumo dos artigos e suas respectivas categorizações de acordo com as 4 perguntas apresentadas anteriormente.

Tabela 2 - Análise e categorização dos artigos selecionados.

Artigos Selecionados	(1)	(2)	(3)	(4)
<i>ALVAREZ et al. (2012)</i>	ACR	Sim	Sim	Não
<i>ASAHARA and KODERA (2012)</i>	ACR	Sim	Sim	Não
<i>DELAKIS et al. (2015)</i>	CDMAM	Sim	Sim	Não
<i>CHEN et al. (2016)</i>	ACR	Não	Não	Sim

GUZMÁN et al. (2019)	ACR	Sim	Sim	Não
KRETZ et al. (2019)	CDMAM	Sim	Sim	Não
SUNDELL et al. (2019)	ACR	Sim	Sim	Não
KRETZ et al. (2020)	CDMAM	Sim	Sim	Não
SUNDELL et al. (2022)	ACR	Sim	Sim	Não
HO, HWANG e TSAI (2022)	ACR	Sim	Sim	Não

A partir da análise dos artigos da Tabela 2, os artigos que relatam pesquisas com maior alinhamento com a pesquisa apresentada nessa dissertação foram selecionados, os quais são detalhados a seguir.

4.1 ABORDAGEM DE ÁLVAREZ ET AL. (2012)

Álvarez et al. (2012), da mesma forma que *Sundell et al. (2019)*, também utilizou DWT e análise de multirresolução. Cada alvo foi extraído separadamente e as funções de base 10 de *Daubechie* foram utilizadas como a “*wavelet* mãe” em todos os procedimentos, a fim de destacar as características estruturas presentes em cada ROI. A justificativa do autor para a escolha desta função base é que ela possui muitas aplicações em processamento de imagem e apresenta melhores resultados qualitativos do que *wavelets* de outras famílias. Após o aprimoramento de DWT das estruturas na imagem, métodos de morfologia matemática foram utilizados para segmentar as estruturas de interesse. Então, as imagens foram binarizadas para estimar a posição das estruturas. Após a binarização, filtros de erosão e dilatação foram aplicados na imagem, a fim de suavizar os objetos na imagem e remover objetos de tamanho pequeno produzidos pela binarização. Após este tratamento de imagem, vários testes foram realizados para segmentar as estruturas correspondentes no *phantom*.

Para aceitar a detecção da massa, a área e a excentricidade (relação entre o foco da estrutura e seu comprimento de eixo principal) da estrutura segmentada foram testadas. Apenas massas com excentricidade $< 0,5$ foram aceitáveis para pontuação. Grupos de massa com área segmentada $\geq 80\%$, dentro de 30% e 80% , ou $< 30\%$ da área do item no *phantom* foram pontuados com notas 1, 0,5 ou 0, respectivamente.

Para aceitação de fibras, excentricidade e ângulo foram testados. Então, somente estruturas com excentricidade $> 0,9$ e ângulo de 35 a 55 graus (para fibras F1, F3 e F5 ROIs) ou 125 a 145 graus (para F2 e F4 fibras ROIs) foram consideradas para pontuação. Em seguida, semelhante aos grupos de massa, áreas segmentadas $\geq 80\%$, dentro de 30% e 80%, ou $<30\%$ da área do item no simulador foi pontuada com notas 1, 0,5 ou 0, respectivamente. Para microcalcificações, apenas estruturas com uma área entre 0,5 e 1,5 vezes a área das microcalcificações correspondentes no *phantom* foram mantidas na ROI. Em seguida, cada microcalcificação foi correlacionada com a primeiro grupo, aquela de maior tamanho. Ela foi usada como a matriz de imagem de referência. Todas as ROIs foram comparadas com a matriz de referência usando o parâmetro de similaridade de correlação. Em seguida, o grupo de microcalcificações foi pontuado de acordo com a quantidade localizada: se 4 a 6 microcalcificações, 3 microcalcificações, ou <3 microcalcificações foram detectadas, então uma pontuação de 1, 0,5 ou 0, respectivamente, foi dado ao grupo. O resultado obtido pelo algoritmo foi comparado a três profissionais, utilizando 30 imagens de *phantom*, com a voltagem do tubo de 23 a 32 kVp, e três níveis de doses glandulares médias (AGDs) para cada kVp resultante em AGDs de 0,11 a 3,4 mGy com Mo/Mo (Molibdênio/Molibdênio) como combinação de ânodo/filtro. O algoritmo proposto obteve capacidade de visualização superior nos casos de massas e fibras. Entretanto, nas microcalcificações, os radiologistas obtiveram escores mais altos, porém, com baixa diferença, quando comparados aos obtidos pelo algoritmo.

4.2 ABORDAGEM DE ASAHARA E KODERA (2012)

Asahara e Kodera (2012) desenvolveram um algoritmo computacional para avaliar automaticamente as imagens do phantom ACR. Ele utilizou as seguintes metodologias: detecção de borda de parafina do *phantom*, correção de não uniformidade do fundo, correção da magnificação e foi calculado o coeficiente de correlação cruzada por técnica de correspondência de imagem. Para que a imagem de referência seja usada na técnica de correspondência de imagem, a cera do *phantom* foi removida e imageada, onde todas as estruturas do phantom podiam ser vistas. Foram utilizados 2 modelos de *phantoms* ACR, com espessura das placas de 2 e 4 cm (*phantoms* ACR com números de série diferentes, que se diferenciam em alguns detalhes), e 10 imagens no total foram obtidas para realizar a avaliação do algoritmo.

Os resultados do algoritmo foram comparados com os resultados médios de seis profissionais qualificados. Os resultados apresentados pelo estudo comprovam que sua metodologia adotada foi semelhante com as pontuações de avaliação dos especialistas observadores. Na avaliação dos grupos de microcalcificações, o algoritmo fez dois erros, em que estruturas pontiagudas foram confundidas com microcalcificações. O autor sugere que esses erros poderiam ser reduzidos se houvesse um processamento aprimorado nas imagens.

Uma desvantagem do estudo citado anteriormente é que a parafina é retirada do objeto simulador, e essa abordagem pode danificar o *phantom*, cujo preço é U\$ 1000 ~ U\$ 1500 (DEPOT, 2022; BIOMEDICAL, 2022; MARKETPLACE, 2022).

4.3 ABORDAGEM DE SUNDEL ET AL. (2019)

Sundel et al. (2019) desenvolveu um *software* para avaliar imagens de um *phantom* ACR para o controle de qualidade de imagem de equipamentos de mamografia utilizando transformadas *wavelets* (DWT) e análise de multirresolução. Apenas o método para a acreditação *phantom* será explorada abaixo.

Primeiramente, a área do *phantom* onde contém a parafina é localizada e isolada, e a imagem é rotacionada para a orientação correta. Cada estrutura (massas, fibras e grupos de microcalcificações) é extraída da imagem e analisada separadamente. A DWT e a análise de multirresolução são utilizadas para aumentar a visibilidade do alvo. A decomposição é feita utilizando as funções de base 45 de *Daubechie*. Após a análise de multirresolução, a imagem é binarizada. Para classificar uma fibra como detectada, o comprimento medido deve estar na faixa de 0,5-1,5 cm. Além disso, o ângulo de fibra medido é usado como um requisito de detecção. Uma pontuação de 0,5 é dada para uma fibra detectada com comprimento < 0,75cm, e 1,0 ponto se for $\geq 0,75$ cm. Para grupos de microcalcificação, três calcificações separadas devem ser encontradas para pontuar 0,5 pontos, e quatro a seis calcificações para ser pontuado 1,0. Uma massa é classificada como detectada se o raio calculado estiver na faixa de 50-100% do raio físico. Para massas detectadas, meio ponto é dado para um raio detectado < 75% e 1,0 ponto para $\geq 75\%$. A circularidade da massa é aplicada como um requisito adicional para detecção.

Os resultados da análise automatizada foram comparados com o de 4 profissionais com diferentes níveis de experiência. Foram utilizadas 80 imagens de *phantoms*: 60 imagens de *phantoms* ACR, selecionadas aleatoriamente, e 20 utilizando dez níveis de dose diferentes (essas imagens foram usadas para validar o *software* com diferentes conteúdos de ruído). A dose média glandular estava na faixa de 0,1-4,1 mGy. A voltagem do tubo era de 28 kVp e as exposições foram de 8, 11, 14, 25, 40, 64, 80, 125, 220 e 320 *mAs*. A combinação ânodo/filtro utilizada não foi especificada.

Portanto, o número médio de fibras detectadas por imagem foi de $4,4 \pm 0,5$ e $4,4 \pm 0,6$ para a análise automatizada e visual, respectivamente. O número médio de detecção do grupo de microcalcificações foi de $4,0 \pm 0,1$ e $3,7 \pm 0,4$ para o método automatizado e visual, respectivamente. E o número médio de massas detectadas foi de $4,2 \pm 0,7$ e $4,1 \pm 0,5$ para a análise automatizada e visual, respectivamente.

4.4 ABORDAGEM DE HO, HWANG e T SAI (2022)

Ho, Hwang e Tsai (2022) desenvolveram um *framework* com o objetivo de automatizar o controle de qualidade de imagem em equipamentos de mamografia. Sua metodologia baseou-se na utilização do algoritmo de *machine learning* denominado *Support Vector Machine* (SVM), e dados tabulares extraídos das subimagens respectivas das estruturas do *phantom* da ACR.

Foram obtidas 461 imagens de *phantom*, obtidas por físicos médicos. O *dataset* foi subdividido em treino (80%) e teste (20%). Primeiramente, foram recortadas as estruturas das imagens do *phantom*, portanto, obteve-se 16 subimagens, cada uma respectiva a uma estrutura: massas, fibras e microcalcificações. O estudo não especifica a metodologia adotada para realizar esse recorte. Cada uma das estruturas possuía uma classe: visível (1), pouco visível (0,5) e não visível (0).

Posteriormente, realizou-se a extração de características de cada uma das subimagens. Essas características foram associadas com informações globais, locais, de posição e de textura da imagem. O recurso de posição indica a localização do das estruturas no *phantom*. As características globais representam a média e o desvio padrão do nível de cinza, o tamanho da matriz, e o gradiente de cada imagem. As características locais representam a média e o desvio padrão dos níveis de cinza dentro da ROI e do fundo da imagem. Também, para as características locais,

extraíram o contraste entre a ROI e o fundo, a taxa de sinal-ruído, o gradiente, e a informação de textura de cada subimagem. Foram extraídas um total de 159 características.

Foram aplicadas algumas técnicas diferentes a fim de avaliar o impacto nos resultados, como, por exemplo, a técnica de *Principal Component Analysis* (PCA), que tem como objetivo a redução de dimensão dos dados de entrada. Foram selecionados um número de componentes que expliquem 95% da variância dos dados. A característica de posição mencionada anteriormente também foi utilizada, e não utilizada, em treinamentos e teste, a fim de avaliar seu impacto nos resultados.

Ao realizar o treinamento e teste utilizando o PCA, o autor comenta que não houve um grande impacto nos resultados, entretanto, o tempo de treinamento ao aplicá-la reduziu drasticamente. Ao remover e inserir a característica de posição, o autor comenta que há um impacto altamente negativo nas métricas, diminuindo em torno 5% para cada estrutura: fibras, massas e microcalcificações. De maneira geral, a metodologia proposta obteve 90,2%, 98,2% e 88,9% de acurácia para fibras, massas e microcalcificações.

4.5 ABORDAGEM DE SUNDEL ET AL. (2022)

Sundell et al. (2022) desenvolveu um método automatizado para o controle de qualidade de imagem em equipamentos de mamografia utilizando algoritmos de *deep learning* e técnicas de processamento de imagens.

O banco de dados utilizado pelo autor foi de rotinas diárias da aquisição de imagens nos testes de controle de qualidade de imagem dos mamógrafos. A fim de obter um banco de dados mais vasto, isto é, imagens com variações em qualidade, o autor alterou o ruído de algumas imagens, seja diminuindo ou aumentando o mesmo. Ao todo, foram utilizadas 800 imagens não alteradas, e 1840 imagens com o seu ruído alterado. Após isso, as imagens foram processadas. Para isso, o autor, inicialmente, recortou a região interna do *phantom* em duas etapas: a primeira, a área do *phantom* foi extraída, baseada na diferença do sinal da região com o fundo da imagem; A segunda, a área interna do *phantom* foi extraída detectando as diferenças abruptas de *pixels* no eixo *x* e *y*. Após isso, as imagens dos *phantoms* foram rotacionadas, quando necessário. Cada uma das estruturas da imagem foi extraída, ou seja, massas, fibras e microcalcificações, gerando, para cada imagem do *phantom*, 16

subimagens. As subimagens foram normalizadas e processadas, posteriormente. Não uniformidades de fundo de baixa frequência foram extraídas da subimagens, utilizando aproximações polinomiais de duas dimensões. Aproximações polinomiais de quinta ordem foram aplicadas nas fibras, e de primeira ordem, nas microcalcificações e nas massas. Noventa por cento (90%) das imagens foram designadas para treino, e 10% para teste. Após isso, foram aplicadas as etapas de treinamento.

Foram treinadas oito arquiteturas de CNNs, a fim de classificar as imagens como visíveis, ou pouco visíveis (classe 1), ou não visíveis (classe 0). A melhor configuração foi aquela que utilizou 6 camadas convolucionais, atingindo uma acurácia geral de 95,2%. Para as fibras, foi obtida uma média e desvio padrão de número de estruturas visíveis de $4,3 \pm 1,4$ e $4,4 \pm 1,3$ para os profissionais, e o método automatizado. Para as microcalcificações, $3,8 \pm 0,8$ para ambos, profissionais e método automatizado. E para as massas, $4,4 \pm 0,9$ e $4,5 \pm 0,8$ para os profissionais e o método automatizado, respectivamente.

5 METODOLOGIA

O presente estudo utilizou linguagem de programação Python. Para isso, foram utilizadas algumas bibliotecas, como *OpenCV*, no processamento de imagens, *Pandas*, para a organização do banco de dados, *Numpy*, na utilização de funções matemáticas, *Scikit-Learn*, para o cálculo de métricas, segregação dos dados e cálculo de pesos, *Keras-Tensorflow*, para a redes neurais convolucionais, *Matplotlib*, para o uso de gráficos nas análises dos resultados obtidos, *Joblib*, para o salvamento dos modelos de *deep learning* desenvolvidos. A Figura 11 apresenta uma visão do fluxo macro do método aplicado nesta pesquisa de mestrado.

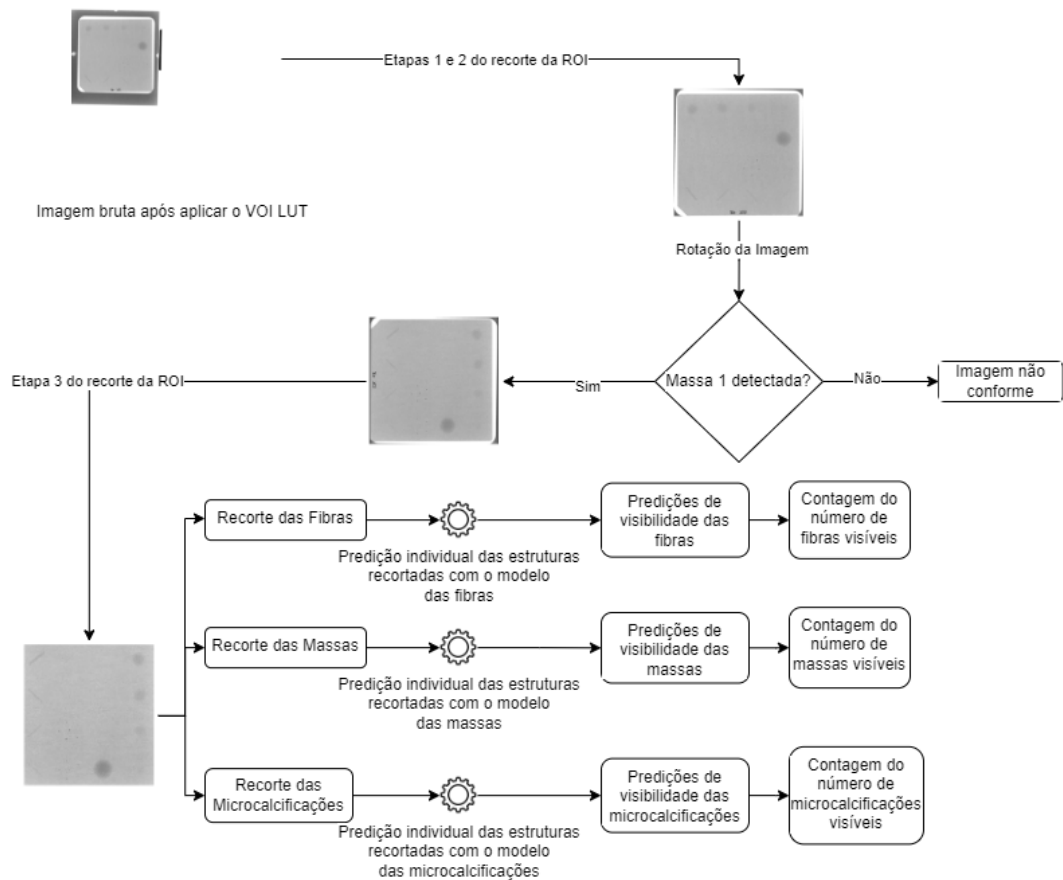


Figura 11 - Fluxograma da metodologia geral utilizada no presente trabalho.

5.1 GERAÇÃO DO BANCO DE DADOS

Para a obtenção de uma metodologia com capacidade de lidar de forma eficaz com o problema proposto nessa dissertação, é necessário um banco de dados vasto, que contemple imagens representando variações de qualidade nas imagens. Este projeto contou com a parceria do serviço de física médica do Hospital de Clínicas de Porto Alegre (HCPA), que foi responsável pelo fornecimento de imagens provenientes do imageamento de objetos simuladores da ACR com os respectivos relatórios de qualidade. O projeto já se encontra aprovado no Comitê de Ética em Pesquisa (CEP) do HCPA e da Universidade Federal de Ciências da Saúde de Porto Alegre (UFCSPA), cujo número de aprovação é 51207721.9.0000.5345, conforme documentos presentes no Anexo A e B, respectivamente.

O banco de dados foi criado a partir de imagens oriundas de testes de qualidade de mamógrafos digitais, que são realizados utilizando um objeto simulador de mama da ACR. Parte dos dados necessários para a geração do banco já existia, em torno de 500 imagens. Tratava-se dos testes de qualidade realizados durante a rotina do serviço de radiodiagnóstico. Essas imagens são armazenadas no sistema do Hospital de Clínicas de Porto Alegre, juntamente com seus respectivos relatórios de qualidade. Tais relatórios foram gerados ao longo do tempo por diferentes profissionais responsáveis pelas análises no HCPA, e foram compartilhadas com os membros da equipe deste projeto.

Uma vez que os equipamentos do HCPA operam na maior parte do tempo em conformidade, as imagens mencionadas anteriormente não apresentam problemas de qualidade. Assim, visando a obtenção de um banco de dados diversificado, novas imagens foram geradas a partir da alteração proposital de parâmetros operacionais do mamógrafo seguida do imageamento do objeto simulador, com o objetivo de obter uma representação de problemas operacionais que impeçam a visualização adequada das estruturas. Estas imagens foram avaliadas e as estruturas contabilizadas, de modo que os relatórios sejam gerados. Foram obtidas 136 novas imagens, totalizando um banco de dados com aproximadamente 570 imagens para a elaboração da pesquisa. Essas imagens foram obtidas variando os parâmetros kVp (23-32) e mAs aleatoriamente, a fim de contemplar as mais amplas variações de qualidade de imagem obtida do simulador da ACR.

O HCPA forneceu uma série de arquivos de formato *DICOM*, os quais contém informações sobre as imagens, além da matriz da imagem, e arquivos *x/sx*, contendo informações dos relatórios de conformidade. Um terceiro arquivo também foi fornecido, o qual correlaciona o nome de cada imagem com o respectivo relatório. Assim, foi necessário realizar a leitura e organização dos dados via *Python*.

5.2 APLICAÇÃO DO VOI LUT

Alguns fabricantes de mamógrafos recomendam que os testes de controle de qualidade sejam realizados sem nenhum tipo de filtragem automática nas imagens, como é o caso de todos os equipamentos do HCPA. Entretanto, para tornar as estruturas visíveis, é necessário realizar um remapeamento dos valores de *pixels*, de forma que mantenha a originalidade da imagem obtida. Esse procedimento é realizado

por um algoritmo denominado VOI LUT. As imagens de raios X de projeção digital geralmente têm uma faixa dinâmica muito alta devido ao desempenho do detector digital. Para exibir essas imagens, várias transformações de valores de interesse (VOI) podem ser aplicadas às imagens para facilitar a interpretação do diagnóstico. (DICOM, 2022). Assim, cada pixel da imagem é reajustado conforme a seguinte lógica:

$$\begin{aligned} & \text{if } (x \leq c - 0.5 - (w - 1)/2), \text{ then } y = y_{min}, \\ & \quad \text{else if } (x > c - 0.5 + (w - 1)/2), \text{ then } y = y_{max}, \\ & \quad \text{else } y = ((x - (c - 0.5)) / (w - 1) + 0.5) * (y_{max} - y_{min}) + y_{min}, \end{aligned}$$

em que x é o valor de intensidade do pixel de entrada, y é o valor de saída com valor mínimo e máximo, respectivamente, y_{min} e y_{max} , c é a janela central e w o tamanho da janela. Os valores c , w , y_{min} e y_{max} são configurados pelo operador durante a geração da imagem e se encontram sempre armazenados com as respectivas imagens no arquivo DICOM. As constantes da equação 5 são determinadas segundo a recomendação da própria metodologia (DICOM, 2022). Com o algoritmo apresentado na Equação 10, os *pixels* das imagens são remapeados. A Figura 12 apresenta o antes (imagem bruta) e o depois (imagem processada) ao aplicar o método descrito anteriormente.




Figura 12 - Representação do procedimento de VOI LUT (a) Antes de aplicar o VOI LUT. (b) Após aplicar o VOI LUT

5.3 PRÉ-PROCESSAMENTO DAS IMAGENS

O procedimento para o recorte da região de interesse (ROI) no presente estudo ocorre em quatro etapas: três recortes (R1, primeiro recorte; R2, segundo recorte; R3, terceiro recorte) e um procedimento de rotação da imagem. Dois recortes ocorrem inicialmente, e o último ocorre após a rotação da imagem, caso seja necessário. Isso é proposto, pois a imagem dos *phantoms* contém múltiplas características e comportamentos diferentes conforme for se aproximando da região de interesse. Dessa forma, foram desenvolvidos quatro métodos em que ocorre o recorte, cada uma personalizada para cada região da imagem, até que o recorte final seja da região principal, ou seja, onde contém apenas as estruturas das imagens. A Figura 13 sumariza o procedimento.




Figura 13 - Diagrama da metodologia de recorte. (a) Imagem com a região especificada para realizar o primeiro recorte. (b) Resultado do primeiro recorte. (c) Imagem com a região especificada para realizar o segundo recorte. (d) Resultado do segundo recorte. (e) Imagem antes de ser rotacionada. (f) Imagem após ser rotacionada. (g) Região especificada para o terceiro recorte. (h) Resultado do terceiro recorte.

Para a realização de todas as etapas de recorte subsequentes, bem como a rotação da imagem, foi realizado utilizando o *framework OpenCV*. Dessa forma, inicialmente a imagem tem seu histograma equalizado utilizando a função *EqualizeHist*, e, por fim, filtrada, utilizando um filtro Guassiano, com a função *GaussianBlur*. O *output* desse processamento é utilizado como *input* na binarização

inversa, utilizando a função *threshold*, atribuindo a configuração de “*thresh_binary_inv*”, em que se define que a aplicação do método de binarização será realizada de maneira inversa. Vale ressaltar que a escolha de utilizar a binarização inversa se deu após testes, a qual demonstrou performar melhor para essa etapa do recorte. A imagem resultante desse procedimento é enviada para a função *findContours*, que tem como objetivo retornar vetores com as coordenadas de regiões localizadas em uma imagem. Para isso, selecionou-se as coordenadas que retornaram a região de maior área da imagem, a qual é representada na Figura 13(a). Esse recorte, após localizar as coordenadas, será realizado utilizando a função *boundingRect*, que tem como objetivo retornar os limites máximos horizontais e verticais de um vetor de coordenadas. Sabendo esses limites, realiza-se o recorte. A Figura 13(b) apresenta o resultado obtido.

A segunda etapa tem como objetivo realizar o recorte na região detalhada em vermelho na Figura 13(c). Para isso, o método abordado será o mesmo do primeiro recorte, entretanto, será utilizado a binarização usual, ao invés da inversa, por ter sido a que melhor performou nesta etapa específica da metodologia. A Figura 13(d) apresenta o resultado obtido.

Na terceira etapa, ocorre o processo de rotação das imagens, caso necessário. De acordo com a região destacada na Figura 14(a), percebe-se que a estrutura com maior visibilidade, quando comparada às demais, é a massa 1. Dessa forma, de maneira geral, o algoritmo proposto baseia-se na sua detecção, cálculo da sua posição e rotação da imagem até a posição correta. A posição correta foi determinada de acordo com a da maioria das imagens do *dataset*. Ou seja, analisou-se o *dataset* e identificou-se qual era a posição na qual a maioria das imagens estavam posicionadas, sendo assim, aquelas em uma posição de rotação diferente foram rotacionadas a fim de mantê-las conforme a maioria do *dataset*. A Figura 14 demonstra a comparação de imagens na posição correta e incorreta.




Figura 14- Comparação entre as imagens com ângulos de posicionamento. (a) Imagem na posição correta. (b) Imagem na posição incorreta.

O algoritmo proposto baseia-se na seguinte lógica: Inicialmente a imagem foi filtrada com um filtro gaussiano, que foi aplicado utilizando a função *GaussianBlur*, removendo ruídos desnecessários. Posteriormente, ela foi equalizada utilizando a função *EqualizeHist*. Após a imagem estar equalizada, foram aplicadas técnicas de morfologia, utilizando o mesmo formato das massas, uma circunferência, a qual foi declarada utilizando a função *getStructuringElement*. Sendo assim, a técnica de morfologia de fechamento, aplicada com a função *MorphologyEx*, irá realizar a remoção de estruturas na imagem que não tenham o mesmo formato de uma circunferência. Após a aplicação da técnica, binarizou-se a imagem, a fim de apresentar apenas as massas na imagem. Restando apenas as massas, utilizou-se a função *HoughCircles*, que tem como objetivo retornar a localização de circunferências. A Figura 15 demonstra o processo descrito acima.




Figura 15 - Etapas de processamento de imagem para realizar a rotação. (a) Imagem na posição incorreta. (b) Imagem filtrada com o filtro gaussiano. (c) Kernel de uma circunferência utilizado. (d) Imagem após aplicar a técnica de morfologia com o kernel apresentado anteriormente. (e) Imagem, após aplicar a morfologia, binarizada. (f) Massa 1 detectada. (g) Imagem rotacionada na posição correta.

A imagem foi separada em 4 quadrantes. Para cada quadrante, há uma rotação a ser realizada. Sabendo, dessa forma, a localização da massa 1, é possível saber em qual quadrante está localizada, e, assim, realizar a devida rotação para que a imagem esteja na posição correta. Caso a massa 1 não fosse detectada em nenhum dos quadrantes, significa que imagem é não conforme, e o processo é finalizado.

Após a imagem rotacionada, a última etapa tem como objetivo realizar o recorte na região especificada em vermelho na Figura 13(g). Duas abordagens foram avaliadas: a primeira, com o *framework ruptures* (TRUONG; OUDRE; VAYATIS, 2020), originalmente proposto para detecção análise e segmentação de sinais não-estacionários e que, neste projeto, foi aplicado com o objetivo retornar os picos de

mudança abruptas de valores de um vetor; A segunda, aplicando recortes manuais considerando a proporção das imagens relacionadas aos picos de mudanças abruptas de valores de pixels, a fim de recortar apenas a região interna do *phantom*, ou seja, onde encontra-se a parafina. As duas metodologias foram comparadas, a fim de definir qual teve melhor desempenho, seja em custo computacional, ou em performance em qualidade de recorte da região-alvo.

Relacionado à primeira metodologia, considerando que uma imagem em escala de cinza é um tensor bidimensional, para utilizar o *framework ruptures*, foi selecionado como vetor para análise a linha central na direção vertical e horizontal da imagem. A Figura 16 ilustra o procedimento. Assim, o algoritmo foi responsável por retornar as coordenadas horizontais e verticais de localização dos picos de diferença de pixels. Além disso, como as imagens do *dataset* utilizadas no presente estudo são de uma rotina prática do HCPA, muitas delas possuem padrões diferentes, ou seja, pequenas variações nas posições e ângulos de posicionamento, dificultando uma generalização no terceiro recorte, retornando coordenadas das diferenças de picos de pixels antes da região especificada em vermelho na Figura 13(g). Para isso, foi definido um valor de margem de segurança no recorte, garantindo que todas as imagens sejam recortadas na região necessária, corrigindo o erro associado ao algoritmo. Esse valor de margem de segurança no recorte foi definido após diversos testes, e foi selecionado aquele que retornasse o melhor resultado. Sendo assim, realiza-se o último recorte.

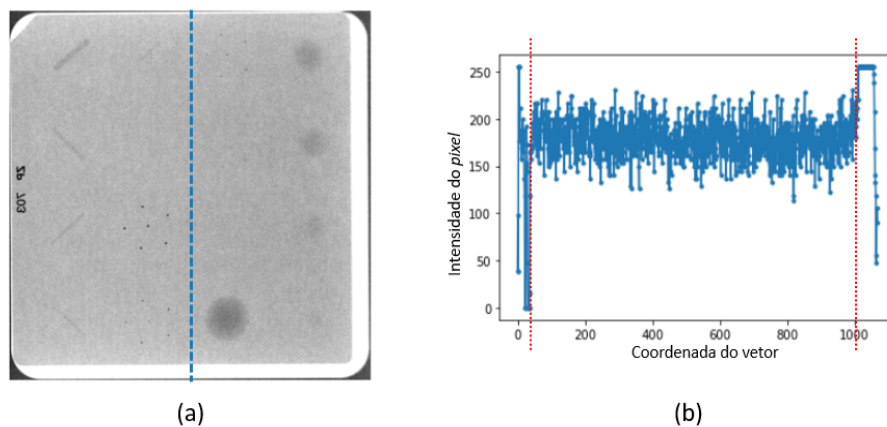


Figura 16 - Exemplo de seleção de coordenadas do terceiro recorte. A Figura (a) ilustra, em azul, o vetor central selecionado para análise. A Figura (b) apresenta o gráfico de intensidade de pixels em relação a posição deste vetor. As linhas em vermelho indicam,

A segunda metodologia se baseia em regras de proporção. Sabendo-se que todas as imagens foram obtidas do mesmo *phantom*, algumas delas apenas com diferenças relacionadas ao posicionamento do *phantom* acima do detector do equipamento de mamografia, e diferenças relacionadas ao tamanho, é válido presumir que, utilizando um fator de proporção único entre elas, seja possível generalizar o recorte interno, tendo apenas uma imagem final com a localização das estruturas, ou seja, a parafina. A Equações 10, 11, 12, 13 e 14 apresentam a metodologia aplicada:

$$img_i = img[(y_{inicial}:y_{final}): (x_{inicial}:x_{final} - \alpha)], \quad (10)$$

Substituindo $y_{inicial}$, y_{final} , $x_{inicial}$ e x_{final} , respectivamente, por:

$$y_{inicial} = int(fator_{y_{inicial}} * length(img)), \quad (11)$$

$$y_{final} = \beta - int(fator_{y_{final}} * length(img)), \quad (12)$$

$$x_{inicial} = int(fator_{x_{inicial}} * length(img)), \quad (13)$$

$$x_{final} = int(fator_{x_{final}} * length(img)), \quad (14)$$


sendo img_i a imagem resultante para a respectiva imagem, img a matriz da imagem após os procedimentos da Figura 13(f), $x_{inicial}$ x_{final} , $y_{inicial}$, y_{final} as respectivas coordenadas iniciais e finais de cada eixo, $length(img)$ o tamanho total da imagem pré-recorte e $fator_{x_{inicial}}$, $fator_{x_{final}}$, $fator_{y_{inicial}}$ e $fator_{y_{final}}$ os respectivos fatores, assumindo valores entre 0 e 1, utilizados para cada coordenada inicial e final de cada eixo. Os parâmetros α e β são parâmetros de ajustes. Todos os fatores foram obtidos após a análise da localização do alvo. Por exemplo, caso a região a ser recortada se encontre na coordenada x igual a 400, e a imagem tenha um tamanho 1000 *pixels*, o fator $fator_{x_{inicial}}$ a ser atribuído é 0,4. Como todas as imagens são iguais, com exceções de mínimas variações, o alvo a ser recortado terá a mesma localização para todas as imagens. Sendo assim, é possível generalizar essa metodologia com um único fator do alvo a ser recortado para todas as imagens.

5.4 RECORTE DAS ESTRUTURAS

Após o pré-processamento das imagens, é necessário realizar a etapa de recorte das estruturas. Essa etapa foi realizada com a justificativa de que é possível avaliar a conformidade através de um modelo binário, ou seja, quais estruturas são visíveis e não visíveis. Além disso, com esse método é possível amplificar o *dataset*. Sendo assim, como a dimensão do objeto simulador e a localização das estruturas são fixas, é possível isolar as regiões que contêm cada tipo de estrutura, realizando recortes delas. Assim, uma proposta que será avaliada é o recorte de cada imagem em 16 novas sub-imagens, onde cada imagem contém uma única estrutura, utilizando a Equação 10 proposta anteriormente.

5.4.1 RECORTE DAS MASSAS

O grupo de massas contém 5 sub-estruturas, as quais vão diminuindo gradativamente sua visibilidade e tamanho, com suas respectivas posições fixas para todas as imagens. Dessa forma, foi utilizada a mesma metodologia com a Equação 10, entretanto, img_i seria relacionado à imagem resultante para a respectiva estrutura do grupo. Os parâmetros da equação foram definidos de forma empírica após sucessivos testes. A equalização de histograma também foi aplicada a fim de manter todas as imagens na mesma faixa de intensidade de pixels. A Figura 17 demonstra o processo seguido acima.



(a)





Figura 17 - Representação do processo de recorte das massas. A circunferência vermelha representa qual estrutura das massas foi recortada. (a) Imagem original. (b) Recorte da massa. (c) Aplicada a técnica de equalização de histograma na imagem recortada.

4.4.2 RECORTE DAS FIBRAS

O grupo de fibras contém 6 sub-estruturas, as quais vão diminuindo gradativamente sua visibilidade, espessura, e com suas respectivas posições fixas para todas as imagens. Dessa forma, foi utilizada a mesma metodologia com a Equação 10, img_i seria relacionado a imagem resultante para a respectiva estrutura do grupo. Os parâmetros da equação foram definidos após sucessivos testes e validações do recorte. A equalização de histograma também foi aplicada a fim de manter todas as imagens na mesma faixa de intensidade de pixels. Além disso, pelo fato de as fibras terem angulações de posicionamento diferentes, todas foram mantidas na angulação da fibra 1 (F1, conforme Figura 1). A figura 18 demonstra o processo seguido acima.



(a)





Figura 18 – Representação do processo de recorte das fibras. A circunferência vermelha representa qual estrutura das fibras foi recortada. (a) Imagem original. (b) Recorte da fibra. (b) Aplicada a técnica de equalização de histograma na imagem recortada.

4.4.3 SEGMENTAÇÃO DAS MICROCALCIFICAÇÕES

O grupo de microcalcificações contém 5 sub-estruturas, as quais vão diminuindo gradativamente sua visibilidade, espessura, e com suas respectivas posições fixas para todas as imagens. Dessa forma, foi utilizada a mesma metodologia com a Equação 10, img_i seria relacionado a imagem resultante para a respectiva estrutura do grupo. Os parâmetros da equação foram definidos após sucessivos testes e validações do recorte. Por outro lado, conforme a Figura 1, pelo fato de as microcalcificações serem semelhantes ao ruído da imagem, presumiu-se que diminuir o ruído iria auxiliar a otimizar os resultados dos futuros modelos. Portanto, foram aplicados filtros derivativos de segunda ordem e um filtro passa-baixa gaussiano. A Figura 19 demonstra o processo seguido acima.



(a)




Figura 19 - Representação do processo de recorte das microcalcificações. A circunferência vermelha representa qual estrutura das microcalcificações foi recortada. (a) Imagem original. (b) Recorte da microcalcificação. (b) Aplicada a técnica de filtro derivativo de segunda ordem e filtro gaussiano.

5.5 TREINAMENTO DOS MODELOS DE *DEEP LEARNING*

5.5.1 ORGANIZAÇÃO DOS CONJUNTOS DE DADOS PARA TREINO, VALIDAÇÃO E TESTE

A segregação dos dados entre treino, validação e teste é uma etapa importante antes de iniciar o treinamento de modelos de *deep learning*. Contudo, no caso em que múltiplos dados são gerados a partir de uma única imagem, é imperativo exercer cautela para evitar a sobreposição de informações provenientes da mesma imagem em conjuntos de dados destinados a treinamento, validação e teste simultaneamente. Isso pode ocasionar um efeito denominado *data leakage*, o qual ocorre quando dados presentes em validação ou teste já foram vistos na etapa de treinamento, obtendo bons resultados, entretanto, enviesados.

Dessa forma, o presente estudo realizou essa segregação diretamente pelo nome das imagens brutas, antes de ter suas estruturas recortadas. Isso garante que todas as estruturas recortadas de uma imagem estejam em apenas uma fase: treino, validação ou teste. Após serem segregadas, as estruturas são extraídas e armazenadas, sendo utilizadas na fase atribuída à sua imagem-fonte. Para a definição da classificação de cada uma das estruturas, visível ou não visível, essa informação foi extraída dos relatórios do HCPA. Lá constava quais massas, fibras, e microcalcificações, são visíveis ou não. Segregando as estruturas a serem utilizadas para treino, validação, e teste, e sabendo quais as suas respectivas classificações, é possível realizar o treinamento dos modelos.

5.5.2 DEFINIÇÃO DA ARQUITETURA DOS MODELOS

As sub-imagens de cada grupo de estruturas foram agrupadas (isto é, grupo das massas, das fibras e das microcalcificações) e, para cada grupo de estruturas, um modelo embasado em *deep learning* foi desenvolvido, cuja saída é um indicador binário, demonstrando se a estrutura é visível ou não. Vale ressaltar que, como o *output* das imagens no treinamento é o parecer do especialista, isso daria a capacidade de ser compatível com a capacidade visual humana.

Será avaliada a utilização de uma rede convolucional pré-treinada associada, a qual serão alimentadas por essas imagens, etapa onde ocorrerá a extração das suas características. Essas características, posteriormente, irão alimentar um classificador binário, responsável por retornar se a estrutura é ou não visível. A seleção da rede convolucional pré-treinada foi definida após múltiplos testes. Aquela que apresentou os melhores resultados, foi selecionada.

5.5.3 AVALIAÇÃO DA PERFORMANCE DOS MODELOS

Para o cálculo da performance dos modelos, utilizou-se as seguintes métricas: Acurácia, sensibilidade, especificidade, receiver-operating-characteristic (ROC), à qual está assimilada a métrica denominada *area under the curve*, (ROC AUC), e a métrica denominada *F1-Score*.

A acurácia é a capacidade geral de classificar todos os dados corretamente. A sensibilidade, a capacidade de classificar os verdadeiros-positivos, no caso da presente pesquisa, as imagens visíveis, sob todos os casos positivos. E a especificidade, a capacidade de classificar os verdadeiros-negativos, no caso da presente pesquisa, as imagens não visíveis, sob todos os casos negativos (HASLWANTER, 2016). As Equações 15, 16, 17 descrevem essas métricas:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}, \quad (15)$$

$$Sensibilidade = \frac{VP}{VP + FN}, \quad (16)$$

$$Especificidade = \frac{VN}{VN + FP}, \quad (17)$$

sendo VP , o número de verdadeiros positivos preditos, VN , o número de verdadeiros negativos, FP , o número de falsos positivos, e FN , o número de falsos negativos.

No que tange a curva ROC, para obtê-la, deve-se declarar diferentes valores de limiares de probabilidade. Os limiares de probabilidade equivalem a um ponto de divisão que realiza a discriminação de uma variável, classificando a presença ou ausência de uma determinada característica investigada nos indivíduos por meio da observação de uma medida aplicada para realizar esta análise. O ponto de divisão demarca um valor para essa medida, determinando assim quais os indivíduos que estão acima ou abaixo desse ponto (MORANA, 2003). Para cada um desses valores, são obtidas suas respectivas taxas de verdadeiros positivos e de verdadeiros negativos, o que resultará na curva ROC. Como maneira de simplificar essa métrica, calcula-se a área abaixo da curva ROC, denominada de AUC. A AUC é um valor entre 0 e 1 que mensura o quão bom está o modelo, de acordo com a curva ROC calculada. Um modelo com AUC igual a 1 é aquele que tem uma perfeita capacidade de separar casos positivos e negativos (HOO *et al.*, 2017). A Figura 20 exemplifica a curva ROC-AUC.

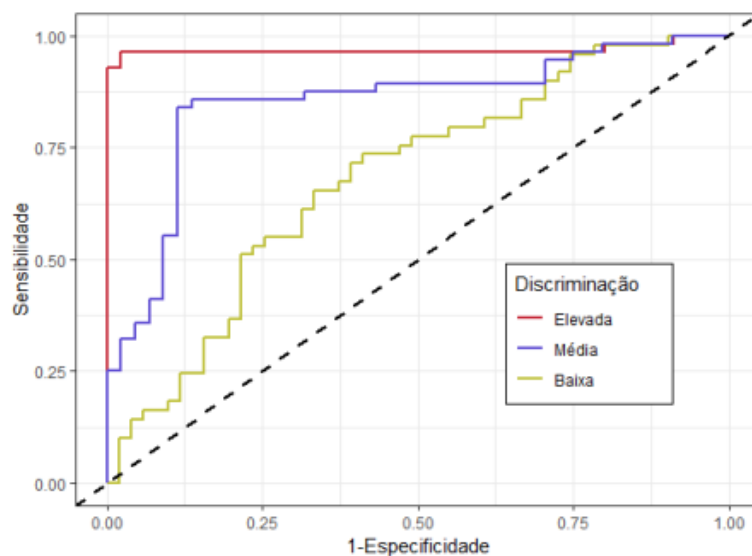


Figura 20 – Fonte: Silva Neto (2020).

O $F1-Score$ é uma métrica utilizada para realizar uma avaliação geral do modelo. Ela assume valores entre 0 e 1. Sendo zero, o pior resultado, e um, o melhor. Ela é obtida conforme a Equação 18:

$$F1 - Score = \frac{2 * TP}{2 * TP + FP + FN'} \quad (18)$$

5.5.4 APLICAÇÃO DA TÉCNICA DE VALIDAÇÃO CRUZADA K-FOLD

Técnicas de validação cruzada serão utilizadas para garantir de que o modelo desenvolvido é genérico o suficiente para qualquer combinação de dados de treino e validação. A técnica de validação cruzada cria múltiplos grupos entre de dados de treino e validação, garantindo que todos os dados presentes para ambas as fases em cada grupo sejam sempre diferentes. Um modelo genérico é aquele que se comporta semelhante em qualquer grupo de dados de treino e teste. No presente estudo, foram selecionados todos os dados de treino e validação segregados anteriormente a essa etapa, com os quais foram realizadas diversas combinações. A Figura 21 demonstra a metodologia aplicada na execução da validação cruzada.



Figura 21 - Exemplificação do funcionamento da metodologia de validação cruzada com K-Fold

5.5.5 REALIZAÇÃO DO TREINAMENTO FINAL

Ao garantir que a metodologia proposta, com a respectiva arquitetura, produz modelos e resultados semelhantes, para qualquer combinação de dados de treino e validação, foi realizado um treinamento comum. Ou seja, foram selecionados todos os dados de treino, e utilizados durante a fase de treinamento. Ao finalizar essa etapa, o modelo produzido foi validado com os dados de teste, obtendo as métricas finais da metodologia.

6 DISCUSSÃO DOS RESULTADOS

6.1 RESULTADOS DO R1 E R2

A metodologia adotada para a primeira e segunda fase do recorte da ROI proposta obteve uma eficácia de 99,30%, ou seja, das 570 imagens utilizadas como *input* nessa fase, 566 foram recortadas corretamente. Para isso, no primeiro recorte, equalizou-se a imagem e a filtrou com um filtro gaussiano, utilizando um kernel de tamanho 9x9. Após isso, a imagem foi binarizadas inversamente, para qual utilizou-se como valor de *threshold* o 240. Ou seja, tudo o que estiver acima desse valor de pixel é mapeado para preto, e abaixo, branco.

Na segunda etapa, os valores de *kernel* e a equalização de histograma aplicada na imagem foram os mesmos da primeira etapa, entretanto, na binarização utilizou-se um *threshold* de 254.

6.2 RESULTADOS DO ROTAÇÃO DAS IMAGENS

Após a primeira e segunda etapa do recorte da ROI, foi aplicada a metodologia aplicada para realizar a rotação de imagens, conforme descrita no capítulo 5.3, utilizou diversas funções da biblioteca *OpenCV*, destinada a processamento de imagens. Algumas delas exigem parâmetros, para que realizem a tarefa a que são destinadas, podendo alterar conforme o objetivo de sua utilização. Vale ressaltar que todos os valores escolhidos foram baseados em múltiplos testes e análises da metodologia. Aqueles que retornavam a melhor performance na rotação, era selecionado.

Na primeira etapa, como descrito no capítulo 5.3, aplicou-se metodologias de processamento de imagem para a rotação. Para tanto, a Tabela 3 demonstram os parâmetros utilizados para cada uma das funções mencionadas anteriormente.

Tabela 3 - Tabela com os valores atribuídos para cada função no primeiro recorte.

Função	Kernel	Sigma	Formato	Raio Mínimo	Raio Máximo	Dist. Min. ¹

¹ Distância entre as circunferências detectadas na imagem.

<i>GaussianBlur</i>	3x3	0^2	N.A. ³	N.A	N.A	N.A
<i>EqualizeHist</i>	N.A.	N.A.	N.A	N.A	N.A	N.A
<i>morph_ellipse</i>	9x9	N.A.	Circunferência	N.A	N.A	N.A
<i>morphologyEx</i> ⁴	N.A.	N.A.	N.A.	N.A	N.A	N.A
<i>HoughCircles</i>	N.A.	N.A.	N.A.	10	50	100000 ⁵

Portanto, das 566 imagens disponíveis, o método proposto de rotação das imagens obteve êxito em 100% das imagens, tanto na questão de sua rotação, quanto na questão de detectar imagens não conformes, as quais tiveram seu processo interrompido antes de realizar a rotação. Quatro imagens tiveram seu processo finalizado antes de rotacionar, pois não foi possível localizar sua massa 1, por serem não conformes. Como são imagens importantes para a pesquisa, pelo fato de terem sido obtidas com parâmetros operacionais diferentes da maneira usual, e por terem uma baixa qualidade, o que pode auxiliar os modelos a serem capaz de compreenderem imagens com baixa qualidade, a rotação delas foi feita de maneira manual. Vale ressaltar que, por mais que a estrutura não fosse detectada, isso demonstra o êxito que o proposto algoritmo teve para realizar a função a que estava designado.

6.3 RESULTADOS DO R3

De acordo com o que foi apresentado no capítulo 5.3, houve 4 fases do recorte para que fosse possível obter apenas a região interna do *phantom*. No que tange o último recorte, foram testadas duas metodologias: uma utilizando a biblioteca *ruptures*, e outro utilizando recortes manuais com regras de proporção. Na utilização da biblioteca *ruptures*, foram utilizados os parâmetros *default*. A metodologia obteve uma performance de recorte abaixo do esperado, com menos de 466 imagens recortadas

² Garante que o valor real do sigma será calculado automaticamente conforme o tamanho do *kernel*.

³ N.A. = Não se aplica

⁴ Técnica de morfologia de fechamento, utilizando o *kernel* declarado em *morph_ellipse*

⁵ O valor atribuído a esse parâmetro se deve ao fato de que é necessário detectar apenas um objeto. Ou seja, definindo uma alta distância entre eles, fará com que o algoritmo detecte, ao menos para a imagem utilizada na presente pesquisa, apenas uma circunferência, visto que as massas na imagem são próximas umas das outras.

corretamente.

Dessa forma, a melhor metodologia que performou foi a segunda, tendo obtido um maior número de imagens recortadas corretamente. Dentre as 566 imagens processadas nessa etapa, 100% delas foram recortadas corretamente. Portanto, de acordo com o que foi proposto na Equação 11, os valores dos parâmetros da equação utilizado para a segunda metodologia de recorte, foram:

- $fator_{x_{inicial}} = 0,1$
- $fator_{x_{final}} = 1$
- $fator_{y_{inicial}} = 0,04$
- $fator_{y_{final}} = 0,04$
- $\alpha = 55$
- $\beta = length(img)$

Os parâmetros foram obtidos após sucessivos testes e análises, a fim de obter os melhores recortes para as imagens do conjunto de imagens oriundos do HCPA, utilizado na presente pesquisa.

6.4 RESULTADOS DO RECORTE DAS ESTRUTURAS

De acordo com a capítulo 5.4, as estruturas foram recortadas utilizando a Equação 11. Para isso, foram definidos parâmetros específicos para cada estrutura, a fim de que fossem recortadas ao redor de sua posição. As Tabelas 5, 6 e 7 demonstram os resultados obtidos no que tange o valor dos parâmetros discutidos para massas, fibras e microcalcificações, respectivamente. Todas as estruturas foram recortadas corretamente, demonstrando que a metodologia adotada utilizando fatores de proporção funcionou corretamente, generalizada para todas as imagens.

Tabela 4 - Fatores utilizados para as respectivas massas

Massas	Fatores			
	$fator_{x_{inicial}}$	$fator_{x_{final}}$	$fator_{y_{inicial}}$	$fator_{y_{final}}$
Massa 1	0,45	0,7	-0,8	$length(img)$
Massa 2	0,7	$length(img)$	0	0,2
Massa 3	0,7	$length(img)$	-0,3	0,5
Massa 4	0,7	$length(img)$	-0,5	0,7

Massa 5	0,7	$length(img)$	-0,8	$length(img)$
----------------	-----	---------------	------	---------------

Os valores de β e α foram setados igual a zero. A Figura 22 demonstra um exemplo dos resultados do recorte, com os respectivos parâmetros da Tabela 4.





Figura 22 - Exemplo das massas recortadas de uma imagem. (a) Massa 1 (b) Massa 2 (c) Massa 3 (d) Massa 4 (e) Massa 5.

Tabela 5 - Fatores utilizados para as respectivas fibras

Fibras	Fatores			
	$fator_{x_{inicial}}$	$fator_{x_{final}}$	$fator_{y_{inicial}}$	$fator_{y_{final}}$
Fibra 1	10	0,17	0	0,2
Fibra 2	0	0,15	-0,25	0,45
Fibra 3	0	0,15	-0,5	0,7
Fibra 4	0	0,15	-0,8	$length(img)$
Fibra 5	0,23	0,4	0	0,2
Fibra 6	0,25	0,4	-0,25	0,45

Os valores de β e α foram setados igual a zero. A Figura 23 demonstra um exemplo dos resultados do recorte, com os respectivos parâmetros da Tabela 5.



(a)

(b)

(c)

(d)

(e)

(f)





Figura 23 - Exemplo das fibras recortadas de uma imagem. (a) Fibra 1 (b) Fibra 2 (c) Fibra 3 (d) Fibra 4 (e) Fibra 5 (f) Fibra 6.

No que tange as microcalcificações, foram utilizadas técnicas de filtragem, a fim de melhorar a diferenciação entre ruído e as estruturas. Foi utilizado um filtro derivativo de segunda ordem, o filtro Laplaciano, com a função *Laplacian* do OpenCV, na qual foi utilizado um kernel de tamanho 7×7 , e um filtro gaussiano, com função *GaussianBlur*, no qual foi utilizado um kernel de tamanho 3×3 , e um sigma igual a zero. Esses valores foram assumidos após múltiplos testes e análises. A Figura 24 demonstra um exemplo dos resultados do recorte, em que há um realce das microcalcificações presentes na imagem, com os respectivos parâmetros da Tabela 6. Os valores de β e α foram setados igual a zero.

Tabela 6 - Fatores utilizados para as respectivas microcalcificações

Microcalcificações	Fatores			
	$fator_{x_{inicial}}$	$fator_{x_{final}}$	$fator_{y_{inicial}}$	$fator_{y_{final}}$
Microcalcificações 1	0,2	0,45	-0,5	0,7
Microcalcificações 2	0,2	0,45	-0,8	Inf
Microcalcificações 3	0,45	0,7	0	0,2
Microcalcificações 4	0,45	0,7	-0,27	0,45
Microcalcificações 5	0,4	0,65	-0,5	0,7






Figura 24 - Exemplo das microcalcificações recortadas de uma imagem. (a) Microcalcificação 1 (b) Microcalcificação 2 (c) Microcalcificação 3 (d) Microcalcificação 4. (e) Microcalcificação 5

O recorte das estruturas, com os parâmetros apresentados no capítulo 5.3, aplicado nas 566 imagens restantes, obteve 100% de êxito. Vale ressaltar que todos os parâmetros atribuídos para o recorte de cada estrutura, preservou-se a proporção entre as imagens, sendo assim, todas tem o mesmo, ou aproximadamente, o mesmo tamanho. Portanto, a Tabela 7 demonstra o número totais de imagens obtidas com o recorte de cada estrutura, bem como a quantidade de estruturas visíveis e não visíveis.

Tabela 7 - Números totais de imagens para cada estrutura, separado por visíveis e não visíveis

Número de Imagens	Massas	Fibras	Microcalcificações
Número total de imagens	2830	3396	2830
Número de imagens visíveis	2283	2324	1723
Número de imagens não visíveis	547	1072	1107

6.5 SEGREGAÇÃO DAS IMAGENS

Conforme a capítulo 5.5.1, a presente pesquisa foi cautelosa na maneira de segregar os dados de treino, validação e teste. A segregação foi baseada no nome do arquivo das imagens, antes de suas estruturas serem extraídas. Portanto, a maneira adotada garantia que as estruturas de uma imagem não estariam em mais de uma fase: treino, validação e teste. Caso alguma classe de estrutura, seja massas, fibras, ou microcalcificações, estivesse tanto em treino, quanto em validação, por exemplo, poderia ocorrer um enviesamento dos resultados. Ou seja, as *features* extraídas das imagens de uma classe de uma estrutura, que seriam aprendidas na fase de treinamento, poderiam ser identificadas novamente na fase de validação, ocasionando bons resultados, mas que, de fato, estariam enviesados.

Dessa forma, foi adotada uma porcentagem de segregação de 80% das imagens para treino, e os restantes 20% estariam segregados entre validação e teste, obtendo 16% e 4% para cada, respectivamente. A Tabela 8 demonstra quantas estruturas, para cada classe, foi atribuída, de acordo com a sua “imagem-fonte”, para cada fase desse processo.

Tabela 8 – Número de imagens para cada estrutura, fase e classificação.

Classificação	Massas			Fibras			Microcalcificações		
	Treino	Validação	Teste	Treino	Validação	Teste	Treino	Validação	Teste
Visível	1822	366	95	1856	374	94	1375	277	71
Não Visível	438	89	20	856	172	44	885	178	44

6.6 TREINAMENTO E RESULTADO DOS MODELOS

6.6.1 SELEÇÃO DA REDE PRÉ-TREINADA

Com as estruturas recortadas, é possível treinar os modelos para cada grupo delas. Previamente ao treinamento, as imagens foram redimensionadas para 224 x 224 x 3. Escolheu-se essa dimensão pelo fato de ser a dimensão *default* das redes pré-treinadas da biblioteca *Tensorflow*. Não foram testadas outras dimensões. Após esse processo, as imagens foram normalizadas.

Com essas respectivas imagens, aquelas designadas ao treinamento e validação são utilizadas para alimentar a rede convolucional pré-treinada, a fim de ter suas respectivas características extraídas. Foram adotadas algumas redes pré-treinadas a fim de serem responsáveis pela extração de características: *InceptionV3*, *VGG16* e *VGG19*.

As características extraídas por essas redes pré-treinadas são utilizadas como entrada de uma rede neural artificial, com camadas totalmente conectadas, a qual dará a predição final: visível ou não visível. Tanto a rede pré-treinada selecionada, quanto a configuração adotada da rede neural artificial foram as mesmas para ambos os grupos de estruturas. A Figura 25 demonstra o processo descrito acima, o qual é aplicado para todas os grupos de estruturas.

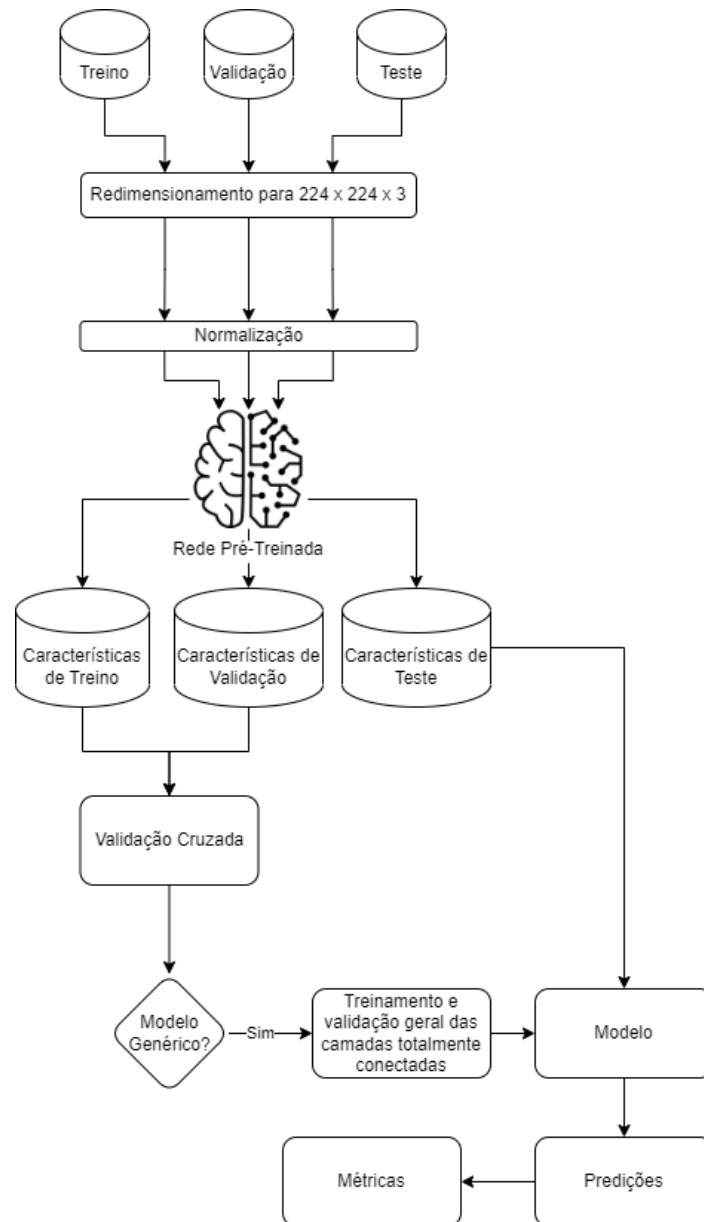


Figura 25 - Diagrama de fluxo do treinamento dos modelos.

A arquitetura adotada para as camadas totalmente conectadas foi:

1. *GlobalMaxPooling2D*
2. Camada densa com 200 nós (função de ativação *ReLU*)
3. Camada densa com 100 nós (função de ativação *ReLU*)
4. Camada densa com 1 nó (função de ativação *Sigmoid*)

Os hiperparâmetros selecionados para o treinamento de cada modelo para

cada grupo de estruturas foram os mesmos. Ou seja, utilizou-se uma função *binary crossentropy*, otimizador *Adam*, um *learning rate* $1e-5$, *batch size* de 64, ao longo de 100 épocas.

Além dos hiperparâmetros, foi utilizada uma técnica a fim de diminuir o impacto do desbalanceamento das classes para cada estrutura. Atribuiu-se pesos para cada classe, ou seja, a classe menos dominante terá um peso maior, quando comparada à mais dominante. Isso faz com que, durante a fase do treinamento, o modelo dê mais relevância à classe menos incidente, que, na presente pesquisa, é a não visível. Para isso, utilizou-se a função *class_weight.compute_sample_weight*, da biblioteca *Scikit-Learn*, que automaticamente atribui pesos, considerando a proporção de dados para cada classe. A Tabela 9 demonstram os pesos atribuídos para cada classe e cada imagem.

Tabela 9 - Valores dos pesos atribuídos para cada classe em cada imagem

Classificação	Massas	Fibras	Microcalcificações
Visível	0,62	0,73	0,82
Não Visível	2,57	1,58	1,27

A fim de realizar uma seleção inicial da rede pré-treinada que performa melhor como extratora de características, cada uma das redes mencionadas anteriormente foi selecionada para extrair as características dos dados de treino e validação. Com a configuração citada anteriormente, foram treinados diferentes modelos para cada grupo de estruturas, utilizando uma rede pré-treinada diferente. Aquela que performasse melhor em cada um dos grupos, seria a selecionada. Vale ressaltar que a os cálculos das métricas foram aplicados apenas utilizando os dados de validação. As Tabelas 10, 11 e 12 resumem os resultados gerais obtidos, com cada rede pré-treinada, para cada grupo de estruturas.

Tabela 10 - Resultados com diferentes redes pré-treinadas para as fibras

Rede Pré-Treinada	Acurácia	Sensibilidade	Especificidade	ROC-AUC	F1-Score
<i>InceptionV3</i>	97,25%	97,05%	97,67%	0,98	0,97
<i>VGG16</i>	93,04%	91,17%	97,09%	0,96	0,94

<i>VGG19</i>	94,13%	93,31%	95,93%	0,97	0,95
--------------	--------	--------	--------	------	------

Tabela 11 - Resultados com diferentes redes pré-treinadas para as massas

Rede Pré-Treinada	Acurácia	Sensibilidade	Especificidade	ROC-AUC	F1-Score
<i>InceptionV3</i>	96,48%	97,26%	93,25%	0,98	0,97
<i>VGG16</i>	93,18%	92,07%	97,75%	0,98	0,95
<i>VGG19</i>	91,68%	90,43%	97,75%	0,98	0,94

Tabela 12 - Resultados com diferentes redes pré-treinadas para as microcalcificações

Rede Pré-Treinada	Acurácia	Sensibilidade	Especificidade	ROC-AUC	F1-Score
<i>InceptionV3</i>	98,46%	97,83%	99,43%	0,99	0,98
<i>VGG16</i>	98,24%	97,47%	99,43%	0,98	0,98
<i>VGG19</i>	98,46%	97,83%	99,43%	0,99	0,98

Sendo assim, a rede neural convolucional pré-treinada que melhor performou foi a *InceptionV3* para todos os grupos. Ao selecioná-la, a arquitetura, a rede pré-treinada e a metodologia proposta foram validadas utilizando a técnica de validação cruzada.

6.6.2 RESULTADOS DA VALIDAÇÃO CRUZADA

A metodologia foi validada utilizando a técnica de validação cruzada, com 5 grupos diferentes entre treino e validação. Para aplicar a técnica de validação cruzada foi utilizada a função *KFold* do *Scikit-Learn*. Vale ressaltar que essa designação de quais imagens seriam utilizadas para treino e validação foi feito utilizando o nome da imagem original, antes de ter suas respectivas estruturas recortadas, garantindo, assim, que estruturas da mesma imagem não estivesse em ambas as fases. As Figuras 26, 27 e 28 demonstram os resultados obtidos da curva de aprendizado para cada classe de estruturas, fibras, massas e microcalcificações, respectivamente.

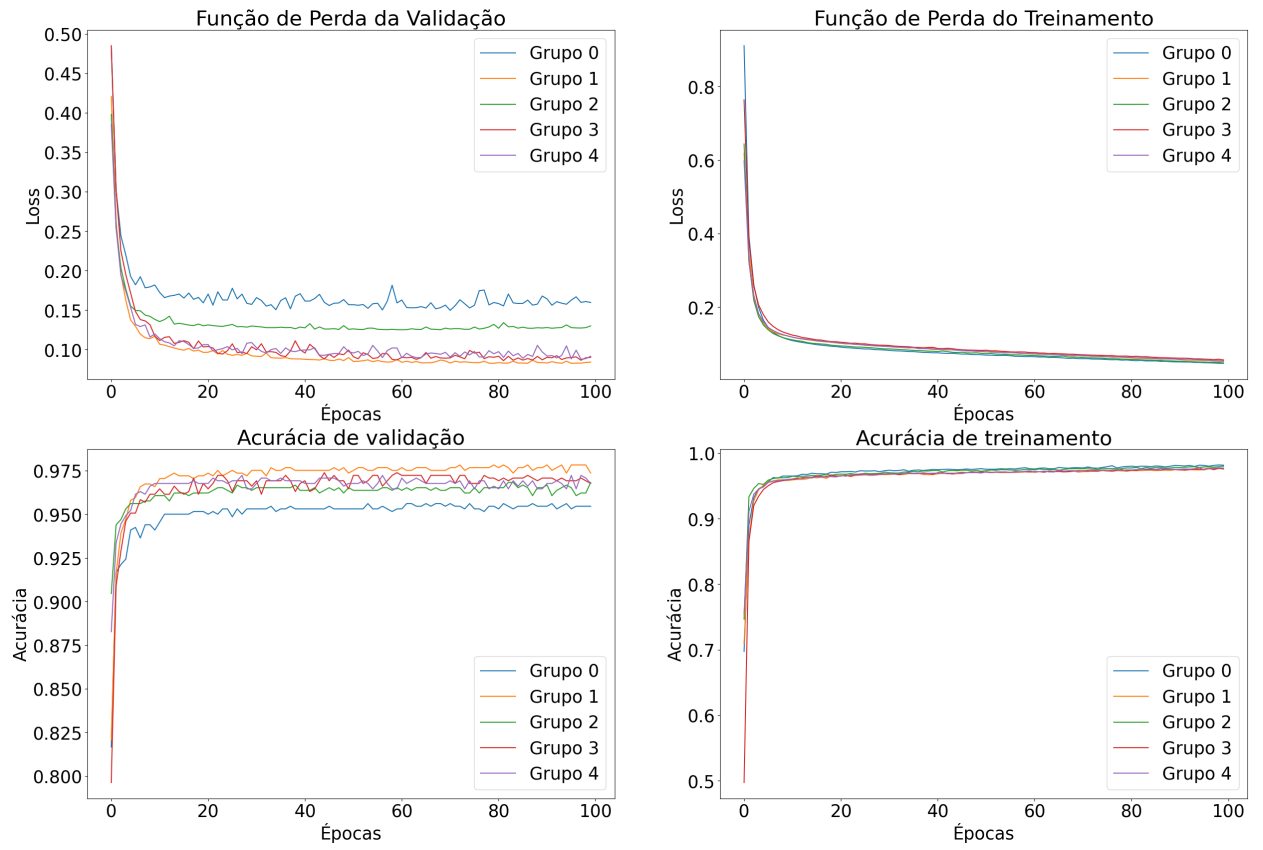


Figura 26 - Curvas de aprendizado do modelo de fibras para cada grupo

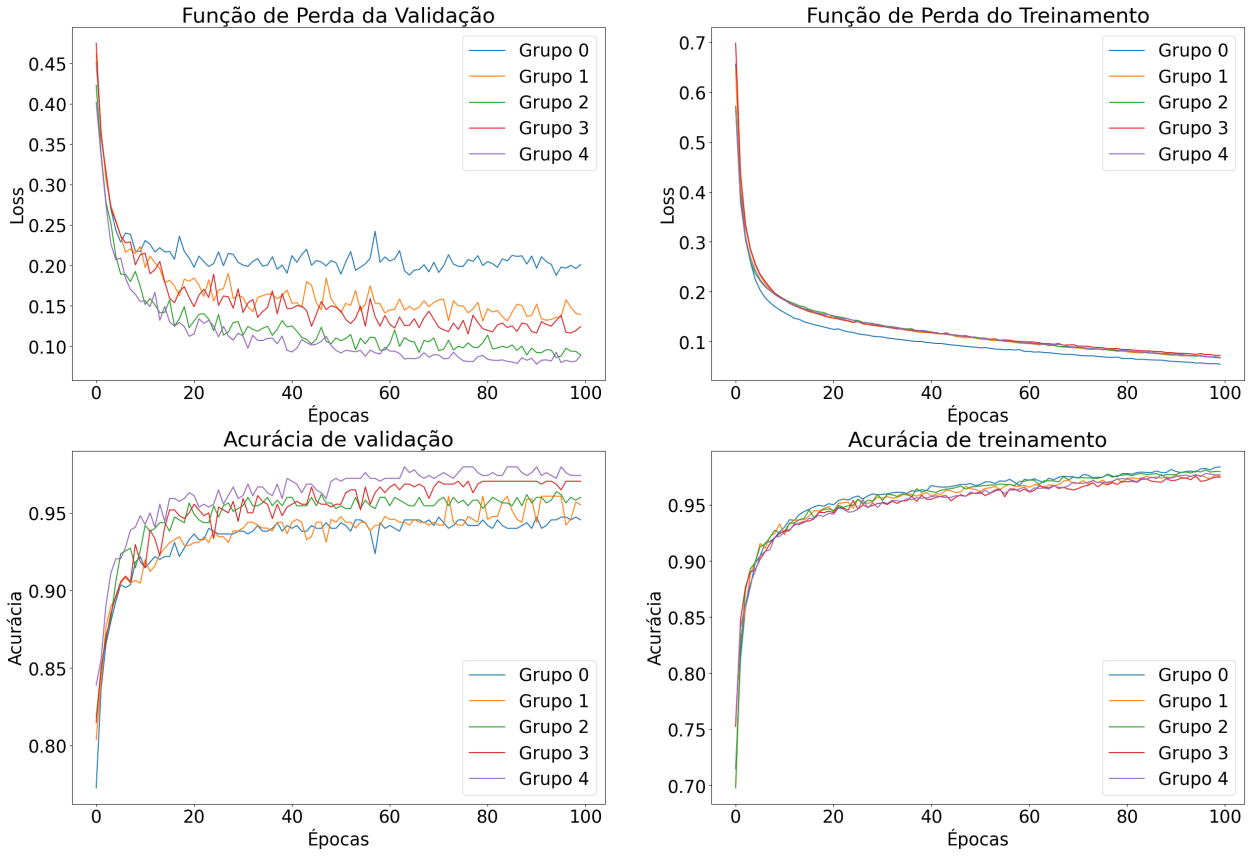


Figura 27 - Curvas de aprendizado do modelo de massas para cada grupo

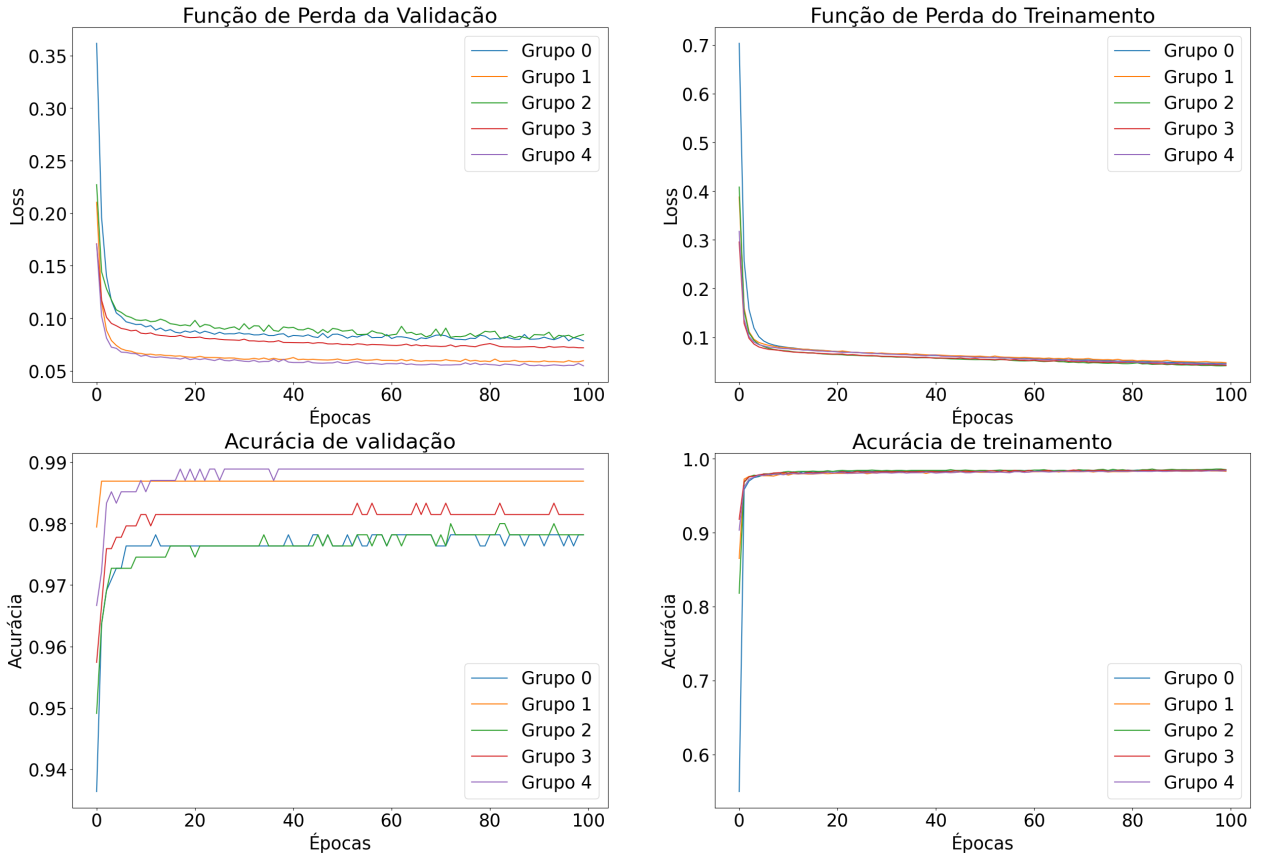


Figura 28 - Curvas de aprendizado do modelo de microcalcificações para cada grupo

Para todas as estruturas, o comportamento de treinamento e validação para cada grupo de treino e validação foi semelhante, pelo fato das curvas, para cada grupo, terem convergido tanto na *loss* quanto na acurácia para valores semelhantes. Esse comportamento, demonstrado com a técnica de validação cruzada, garante que, independentemente de quais dados de treino e validação forem utilizados, os resultados serão semelhantes, com um desvio padrão associado. Sendo assim, a Tabela 13 demonstra os resultados médios, e seu desvio padrão, para cada grupo de treino e validação, relacionado ao respectivo modelo de sua classe de estrutura.

Tabela 13 – Resultados médios de cada grupo para cada modelo treinado de cada estrutura

Métricas	Fibras	Massas	Microcalcificações
Acurácia Média ± Desvio Padrão	96,96% ± 0,77	95,77% ± 1,03	98,31% ± 0,44
Sensibilidade Média ± Desvio Padrão	96,10% ± 0,90	96,08% ± 1,10	97,58% ± 0,84
Especificidade Média ± Desvio Padrão	98,84% ± 0,68	94,49% ± 1,12	99,43% ± 0,46
ROC-AUC Médio ± Desvio Padrão	0,98 ± 0,00	0,98 ± 0,00	0,99 ± 0,00
F1-Score ± Desvio Padrão	0,98 ± 0,00	0,97 ± 0,00	0,98 ± 0,00

Dessa forma, os resultados obtidos, conforme as figuras anteriores, e a Tabela 13, comprovam altos valores médios das métricas, e um baixo desvio padrão. Isso garante a reprodutibilidade dos resultados, independentemente de quais dados utilizar em cada fase: treinamento ou validação.

6.6.3 RESULTADOS COM OS DADOS DE TESTE

Demonstrado que os modelos são genéricos o suficiente para qualquer combinação de dados de treino e validação, foi confirmado que tal metodologia proposta tem boa performance em diferentes grupos de treino e validação. Portanto, foi realizado um treinamento geral, utilizando todos os dados de treino. Os dados de validação foram utilizados na presente etapa apenas para avaliação das curvas de aprendizado, a fim de garantir que estavam com bom comportamento durante o treinamento. Entretanto, as métricas finais dos modelos foram calculadas com os dados de teste. As curvas de aprendizado desses treinamentos e validações, com a arquitetura adotada e os hiperparâmetros selecionados, estão dispostas conforme a Figura 29, 30 e 31, para massas, fibras e microcalcificações, respectivamente.

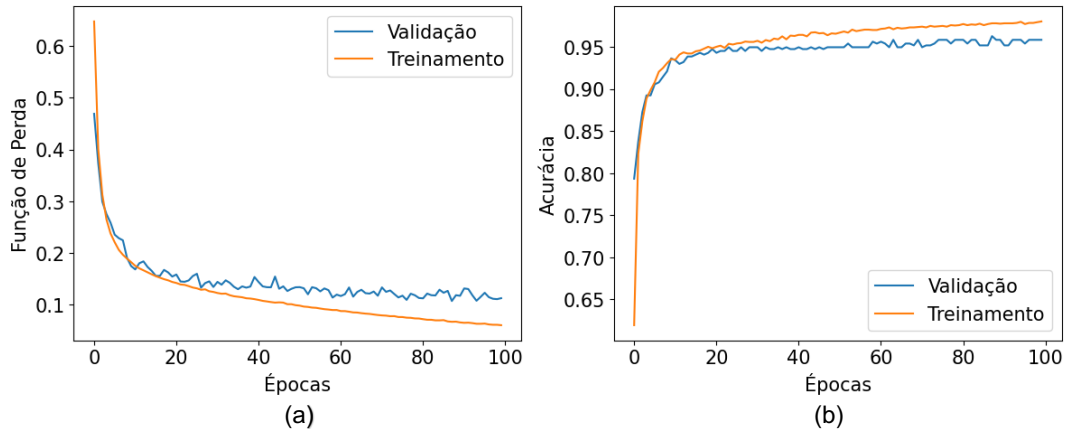


Figura 29 - Curvas de aprendizado do modelo treinado para as massas. (a) Curva da *loss*. (b) Curva da acurácia.




Figura 30 - Curvas de aprendizado do modelo treinado para as fibras. (a) Curva da *loss*. (b) Curva da acurácia.

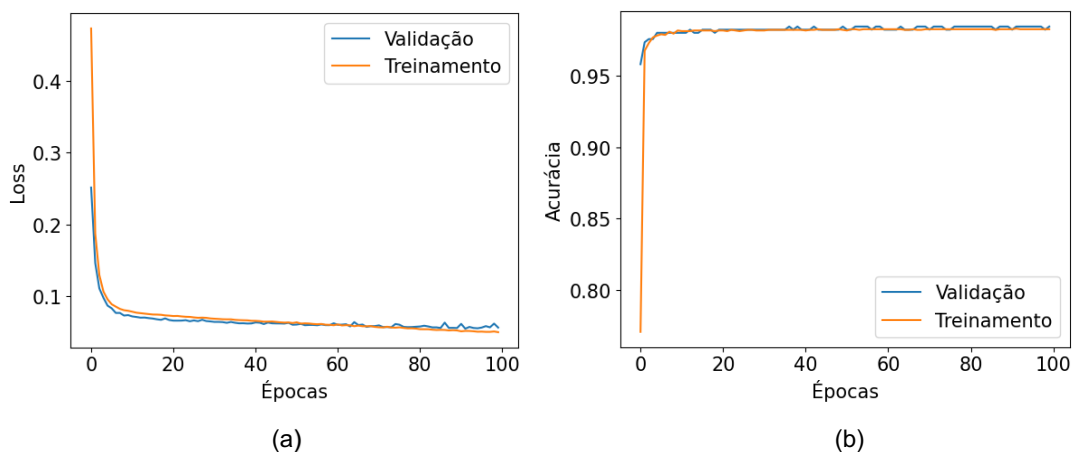


Figura 301 - Curvas de aprendizado do modelo treinado para as microcalcificações. (a) Curva da *loss*. (b) Curva da acurácia.

De maneira geral, conforme esperado, as curvas de aprendizado para todas as

classes de estruturas demonstram, o aprendizado do modelo desenvolvido. Não há indícios de *overfitting* ou *underfitting*. Os gráficos das curvas *loss* demonstram, tanto para validação, quanto para treino, a convergência, além disso, ambas curvas de treino e validação apresentam comportamentos semelhantes. Dessa forma, com os modelos treinados e garantindo-os seu bom comportamento durante o treinamento e validação, foram obtidos os resultados com os dados de teste. A Tabela 14 sumariza os resultados obtidos de cada modelo.

Tabela 14 - Resultados com os dados de teste

Métrica	Fibras	Massas	Microcalcificações
Acurácia	96,38%	96,52%	94,78%
Sensibilidade	95,74%	95,79%	94,34%
Especificidade	97,73%	100%	95,45%
<i>F1-Score</i>	0,97	0,98	0,96
<i>ROC AUC</i>	0,99	0,99	0,95

A Figura 32 demonstram os gráficos da curva ROC AUC obtida com os dados de teste para cada classe de estruturas.




Figura 31 - Curva ROC AUC para cada classe de estruturas

Os resultados obtidos, conforme a Tabela 14 e a Figura 32, demonstram a eficácia e o quão promissor é o método. Por outro lado, é condizente olhar os resultados, e o comportamento das previsões, isolados para cada estrutura. As Figuras 33, 34 e 35 demonstram as previsões obtidas pelo modelo, comparada com a sua classificação real. O eixo das ordenadas demonstra a probabilidade de ser positivo, ou seja, visível. As cores demonstram a classificação real de cada uma delas.




Figura 32- Distribuição de previsões comparadas a classificação real das massas.




Figura 33 - Distribuição de previsões comparadas a classificação real das fibras.




Figura 34 - Distribuição de previsões comparadas a classificação real das microcalcificações.

É possível perceber, de acordo com os resultados presentes nas Figuras 33, 34 e 35, que as previsões para cada estrutura são condizentes com os resultados demonstrados na Tabela 14. Não há uma discrepância de acertos entre as estruturas. Entretanto, percebe-se uma dificuldade do modelo, ainda que sutil, de segregar entre visível e não visível para as últimas estruturas. Porém, o método comporta-se de

maneira promissora, demonstrando bons resultados para a segregação das estruturas entre visível e não visível, tendo possibilidade de aplicação na área clínica a fim de auxiliar os serviços de física médica.

Ao comparar o número médio, e seu desvio padrão, de estruturas visíveis obtidos da metodologia proposta com os dos profissionais, aplicou-se o mesmo procedimento de *Sundell et al., (2019)*, o qual comparou a capacidade de visualização de sua metodologia, com o de profissionais. A Tabela 15 demonstra os resultados da metodologia do presente estudo e os resultados obtidos por *Sundell et al., (2019)* e *Sundell et al., (2022)*.

Tabela 15 - Resultados obtidos por (a) *Sundell et al., (2019)*, (b) *Sundell et al., (2022)* e, (c) metodologia proposta, avaliados por (1) profissionais e (2) método automatizado

	Avaliador	Fibras	Massas	Microcalcificações
(a)	1	4,4 ± 0,5	4,1 ± 0,5	4,0 ± 0,1
	2	4,4 ± 0,6	4,2 ± 0,7	3,7±0,4
(b)	1	4,3 ± 1,4	3,8 ± 0,8	4,4 ± 0,9
	2	4,4 ± 1,3	3,8 ± 0,8	4,5 ± 0,8
(c)	1	4,1 ± 0,4	4,1 ± 0,3	3,0 ± 0,6
	2	4,0 ± 0,0	4,0 ± 0,4	3,0 ± 0,0

De acordo com a Tabela 15, todos os resultados da metodologia proposta tiveram pouca diferença, quando comparado ao dos profissionais. Entretanto, a literatura, conforme Seção 4, e os resultados inseridos na Tabela 15, assumem que um maior número de estruturas detectadas da sua respectiva metodologia, melhor são os resultados. Entretanto, não há discussões acerca do limite de visibilidade da metodologia. Ao desenvolver uma metodologia com um objetivo da presente pesquisa, é de suma importância que se desenvolva um método que não exceda os limites visuais humanos. Dessa forma, o presente estudo assumiu como suma relevância este aspecto, o que foi possível conforme os resultados da Tabela 15, além das métricas obtidas para cada estrutura, de acordo com a Tabela 14. A metodologia proposta na presente pesquisa foi, de certa forma, conservadora no que tange melhorar a qualidade da imagem, a fim de não obter modelos que excedam a capacidade humana de visualização. Com isso, é possível afirmar que o presente método desenvolvido pode auxiliar serviços de física médica a automatizarem o controle de qualidade de imagem em equipamentos de mamografia, garantindo uma

performance semelhante à de profissionais, e removendo a subjetividade atrelada ao controle de qualidade.

Por outro lado, também, o estudo alcançou métricas de acurácia superior quando comparada às metodologias que utilizaram técnicas de *machine learning*, ou *deep learning*, conforme é apresentado na Tabela 16.

Tabela 16 - Comparação de acurácia da metodologia proposta com o de outros estudos

	Fibras	Massas	Microcalcificações
Metodologia Proposta	96,38%	96,52%	94,78%
<i>Ho, Hwang e Tsai (2022)</i>	90,2%	98,2%	88,9%

Para o grupo de fibras e microcalcificações, a metodologia proposta obteve métricas de acurácia superiores. Apenas para as massas obteve uma acurácia inferior, ainda que com uma baixa diferença. Entretanto, o estudo de *Ho, Hwang e Tsai (2022)* menciona que as suas métricas melhoraram ao inserir a característica de posição das estruturas. De certa forma, ao inserir essa informação no treinamento do algoritmo, há um bom resultado, entretanto, enviesado. Isso se deve pelo fato de que o modelo está compreendendo que certas estruturas em posições específicas são sempre visíveis ou não visíveis. Por exemplo, caso houvesse uma rotação da imagem do *phantom*, suas estruturas estariam em outras localizações, e as fibras, por exemplo, as quais cada uma delas tem uma característica da sua posição atrelada, agora estaria em uma posição completamente diferente daquela utilizada no treinamento, e o modelo não seria capaz de prever com uma boa acurácia a sua visibilidade.

Por outro lado, o estudo de *Sundell et al., (2022)* menciona ter atingido uma acurácia geral de 95,20%. O presente estudo atingiu uma acurácia de 95,92%, o que indica 0,72% a mais. A metodologia proposta e a de *Sundell et al., (2022)* basearam-se na utilização algoritmos de *deep learning*, atrelados a processamento de imagem, o que as torna semelhantes, e obtendo resultados próximos. Entretanto, o estudo de *Sundell et al., (2022)* utilizou uma arquitetura própria, realizando todas as etapas do treinamento e das operações de CNNs desde o início, sendo treinada em mais de 200 épocas. Por outro lado, o presente estudo utilizou redes pré-treinadas, utilizando pesos já pré-atribuídos vindos de um treinamento prévio no *dataset ImageNet*, sendo capaz de extrair as características das imagens fora do processo de treinamento,

sendo necessário apenas o treinamento das camadas totalmente conectadas, responsáveis pela classificação final. Isso auxilia no custo computacional, o que a torna pouco custosa computacionalmente, sendo capaz de ser treinada em apenas 100 segundos (em média, 1 segundo para cada época do treinamento), com uma GPU RTX 3050 8GB, 16GB RAM e processador i5-10400. Tais métricas demonstradas anteriormente, bem como o pouco custo computacional, demonstram que a eficácia da metodologia proposta é altamente promissora, sendo capaz de se destacar quando comparada a metodologias semelhantes da área. Por outro lado, ao analisar os macros resultados disponibilizados pelo autor, a Tabela 17 demonstra uma comparação dos resultados para cada estrutura. Essa comparação foi proposta de acordo com a tabela disponibilizada no capítulo de resultados do artigo do estudo de *Sundell et al., (2022)*.

Tabela 17 - Resultados comparados com os de *Sundell et al., (2022)*

	Metodologia Proposta	<i>Sundell et al., (2022)</i>
Estrutura	Acurácia	Acurácia
Fibra 1	100%	100%
Fibra 2	100%	98,60%
Fibra 3	100%	98,60%
Fibra 4	95,65%	96,00%
Fibra 5	86,95%	93,80%
Fibra 6	100%	80,00%
Massa 1	100%	100%
Massa 2	100%	98,70%
Massa 3	100%	93,90%
Massa 4	91,30%	98,30%
Massa 5	86,95%	89,50%
Microcalificação 1	100%	100%
Microcalificação 2	100%	98,70%
Microcalificação 3	100%	96,10%
Microcalificação 4	91,30%	97,20%
Microcalificação 5	86,95%	94,40%

Apesar de, para algumas estruturas, especialmente as últimas estruturas para cada grupo, terem tido acurácia inferior, a acurácia geral da metodologia proposta foi superior, como mencionado anteriormente, demonstrando a eficácia da metodologia proposta no presente estudo.

7 DESENVOLVIMENTO FUTURO

7.1 RECONSTRUÇÃO DA IMAGEM E ANÁLISE DE CONFORMIDADE

As imagens recortadas na etapa anterior serão reconstruídas de acordo com o identificador previamente definido, ou seja, a posição de cada uma das estruturas, a qual é fixa. O processo de verificação de conformidade ocorrerá nesse momento, em que as estruturas preditas como visíveis pelo modelo de *deep learning* serão contabilizadas, os quais devem estar dentro dos limites especificados no capítulo 2.3.1. Caso a contabilização esteja abaixo dos limites estabelecidos pela RDC 611 IN 92, é classificado como não-conforme. No que tange a localização das estruturas, é reproduzida a mesma metodologia utilizada na Equação 6, em que as estruturas têm sua localização fixa em todas as imagens. Tendo conhecimento do fator para cada uma das coordenadas, é possível extraí-las para serem preditas futuramente.

7.2 DESENVOLVIMENTO DO *FRAMEWORK*

As etapas anteriores serão consolidadas em um *framework*, em que o usuário fornecerá uma imagem e a saída será o número de estruturas visíveis para cada grupo, indicando se é uma imagem conforme ou não. Vale ressaltar que esse *framework* será validado com o apoio de profissionais da área do HCPA, os quais deverão assinar o Termo de Compromisso Livre Esclarecido (TCLE) conforme modelo apresentado no Anexo C.

8 CONCLUSÃO

O presente estudo tem como objetivo desenvolver um método computacional para análise de imagens de simuladores da ACR baseado em técnicas de processamento digital de imagens combinadas a técnicas de *deep learning* para o controle de qualidade de imagem em mamógrafos, a fim de responder a seguinte questão norteadora: “Qual seria o diferencial quantitativo da aplicação de algoritmos de *deep learning* no contexto do problema proposto, em relação às metodologias

atuais da literatura?”. De acordo com os resultados obtidos, ao utilizar o método proposto nessa dissertação, percebe-se que há um ganho de acurácia, no que tange a classificação de visibilidade de estruturas do simulador da ACR, tanto para classificar o grupo das massas, fibras ou microcalcificações. O método conta com etapas minuciosas e detalhadas de processamento digital de imagens, combinadas a utilização de redes neurais convolucionais pré-treinadas. Ao utilizar redes pré-treinadas como extratora de características das imagens, houve um ganho de esforço computacional, visto que não foi necessário o treinamento total dessas redes neurais convolucionais, além de um ganho de acurácia. Comparando aos estudos mais semelhantes com o proposto na presente pesquisa, *Sundell et al. (2022)* obteve um acurácia geral 0,72% menor quando comparado ao dessa dissertação. Por outro lado, *Ho, Hwang e Tsai (2022)* obteve uma acurácia de classificação das fibras e microcalcificações de 6,18% e 5,88%, respectivamente, menor quando comparado ao método proposto. Entretanto, no que tange a acurácia de classificação de visibilidade das fibras, ele obteve apenas 1,68% maior.

Ao validar os modelos treinados em técnicas de validação cruzada, a metodologia proposta se apresentou reprodutível, sendo capaz de atingir resultados semelhantes, independente da combinação de dados de treino e validação, obtendo $96,96\% \pm 0,77$, $95,77\% \pm 1,03$ e $98,31\% \pm 0,44$ de acurácia para fibras, massas e microcalcificações, respectivamente. O baixo desvio padrão atrelado aos valores médios da acurácia demonstram a semelhança dos resultados para cada grupo da validação cruzada. Além disso, os altos valores das métricas calculadas, bem com o comportamento de predição individual de cada estrutura, conforme as Figuras 27, 28 e 29, demonstram a capacidade do método.

Por outro lado, conforme a Tabela 12, o número médio de estruturas visíveis, quando comparando o presente método com o de profissionais, foi semelhante, nos quais os profissionais obtiveram uma média de estruturas visíveis de $4,08 \pm 0,40$, $4,13 \pm 0,33$ e $3,08 \pm 0,58$ para fibras, massas e microcalcificações. A metodologia proposta obteve $4,0 \pm 0,3$, $3,9 \pm 0,2$ e $3 \pm 0,0$ para fibras, massas e microcalcificações. Esse fato reforça o tema discutido anteriormente, em relação a importância de desenvolvimento de um método que não exceda os limites visuais humanos, visto que na literatura não há discussões acerca disso.

Pelo fato de ter sido utilizado um banco de dados oriundo do HCPA, a presente pesquisa pode estar limitada a ser aplicada apenas nas mesmas condições do

hospital, ou seja, mesmos equipamentos, mesmos simuladores da ACR e imagens semelhantes.

No que tange as perspectivas futuras, é necessário finalizar a implementação da análise de conformidade final, na qual as estruturas previstas como visíveis serão contabilizadas, a fim de retornar um *output* de conformidade. Além disso, toda o estudo será consolidado em um *framework*.

REFERÊNCIAS

- ABDOLALI, F. et al. **Automated thyroid nodule detection from ultrasound imaging using deep convolutional neural networks**, 2020.
- ALVAREZ, M. et al. Application of wavelets to the evaluation of phantom images for mammography quality control. **Physics in Medicine & Biology**, v. 57, n. 21, p. 7177, 2012.
- ASAHARA, Masaki; KODERA, Yoshie. Computerized scheme for evaluating mammographic phantom images. **Medical Physics**, v. 39, n. 3, p. 1609-1617, 2012.
- ARAÚJO, Flávio HD et al. Redes neurais convolucionais com tensorflow: Teoria e prática. **SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos**, v. 1, p. 382-406, 2017.
- BARRAGAN, C. M. V. **Desenvolvimento de algoritmos para avaliação da imagem do Simulador Phantom mama para o controle de qualidade em mamografia**. [s.l.] Universidade Federal de Minas Gerais, 2016.
- BROOKS, K. W.; TRUEBLOOD, J. O. N. H.; KEARFOTT, K. J. Subjective Evaluations of Mammographic Accreditation Phantom Images by Three Observer Groups. **Investigative Radiology**, v. 29, n. 1, 1994.
- BIOMEDICAL, Fluke. **ACR Mammography Accreditation Phantom**. Disponível em: <https://www.flukebiomedical.com/products/radiation-measurement/phantoms-test-tools/18-220-acr-mammography-accreditation-phantom>. Acesso em: 14 abr. 2022.
- CASTIGLIONI, Isabella et al. AI applications to medical images: From machine learning to *deep learning*. **Physica Medica**, v. 83, p. 9-24, 2021.
- CHEN, C.-Y. et al. Optimizing quality of digital mammographic imaging using Taguchi analysis with an ACR accreditation phantom. **Bioengineered**, v. 7, n. 4, p. 226–234, jul. 2016.

SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

CHOLLET, François. Xception: *Deep learning* with depthwise separable convolutions. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2017. p. 1251-1258.

CHOLLET, Francois. ***Deep learning with Python***. Simon and Schuster, 2021.

DELAKIS, Ioannis et al. Performance evaluation of contrast-detail in full field digital mammography systems using ideal (Hotelling) observer vs. conventional automated analysis of CDMAM images for quality control of contrast-detail characteristics. **Physica Medica**, v. 31, n. 7, p. 741-746, 2015.

DENG, Jia et al. Imagenet: A large-scale hierarchical image database. In: **2009 IEEE conference on computer vision and pattern recognition**. Ieee, 2009. p. 248-255.

DEPOT, Medical Device. **CIRS ACR Digital Mammography Phantom**. Disponível em: <https://www.medicaldevicedepot.com/ACR-Digital-Mammography-Phantom-p/086.htm>. Acesso em: 14 abr. 2022.

DICOM. DICOM PS3.3 2022a - Information Object Definitions - C.11.2 VOI LUT Module. 2022. Acessado em: 10/02/2022. Disponível em: https://dicom.nema.org/medical/dicom/current/output/chtml/part03/sect_C.11.2.html

GAO, Yuan et al. Deep learning and transfer learning models of energy consumption forecasting for a building with poor information data. *Energy and Buildings*, v. 223, p. 110156, 2020.

GONZALEZ, Rafael C.; WOODS, Richard E. Digital image processing. upper saddle River. **J.: Prentice Hall**, 2002.

GRABER, M. L.; FRANKLIN, N.; GORDON, R. Diagnostic error in internal medicine. *Archives of Internal Medicine*, v. 165, n. 13, p. 1493–1499, 11 jul. 2005. DOI 10.1001/archinte.165.13.1493.

GUZMÁN, Valentina Corchuelo; RESTREPO, Hernán Darío Benítez; HURTADO, Edison Salazar. Natural Scene Statistics of Mammography Accreditation Phantom Images. In: **2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)**. IEEE, 2019. p. 1-5.

HASLWANTER, Thomas. An Introduction to Statistics with Python. **With Applications in the Life Sciences.. Switzerland: Springer International Publishing**, 2016.

HAYKIN, Simon. **Neural networks and learning machines**, 3/E. Pearson Education India, 2010

HE, Kaiming et al. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 770-778.

HO, Pei-Shan; HWANG, Yi-Shuan; TSAI, Hui-Yu. Machine learning framework for automatic image quality evaluation involving a mammographic American College of Radiology phantom. **Physica Medica**, v. 102, p. 1-8, 2022.

HOPE, Tom; RESHEFF, Yehezkel S.; LIEDER, Itay. Learning tensorflow: A guide to building deep learning systems. " O'Reilly Media, Inc.", 2017.

HOO, Zhe Hui; CANDLISH, Jane; TEARE, Dawn. What is an ROC curve? **Emergency Medicine Journal**, v. 34, n. 6, p. 357-359, 2017.

HOWARD, Andrew G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. **arXiv preprint arXiv:1704.04861**, 2017.

HUANG, Gao et al. Densely connected convolutional networks. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2017. p. 4700-4708.

INSTITUTO NACIONAL DE CÂNCER. **Câncer de Mama**. Disponível em: <<https://www.inca.gov.br/tipos-de-cancer/cancer-de-mama>>. Acesso em: 05 abr. 2022.

INSTRUÇÃO NORMATIVA Nº 92, DE 27 DE MAIO DE 2021. Brasil, 2021. Disponível em: <<https://www.in.gov.br/en/web/dou/-/instrucao-normativa-in-n-92-de-27-de-maio-de-2021-322985226>>

SAMPAIO, S. C. Modelagem e implementação orientada a objetos de um cliente de rede para banco de dados de imagens médicas digitais utilizando o padrão DICOM 3.0. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 1999.

SZEGEDY, Christian et al. Rethinking the inception architecture for computer vision. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 2818-2826.

SOUZA, Marcela Tavares de; SILVA, Michelly Dias da; CARVALHO, Rachel de. Revisão integrativa: o que é e como fazer. **Einstein (São Paulo)**, v. 8, p. 102-106, 2010

SUNDELL, Veli-Matti et al. Automated daily quality control analysis for mammography in a multi-unit imaging center. **Acta Radiologica**, v. 60, n. 2, p. 140-148, 2019.

SUNDELL, Veli-Matti et al. Convolutional neural network-based phantom image scoring for mammography quality control. **BMC Medical Imaging**, v. 22, n. 1, p. 1-14, 2022.

TAN, Mingxing; LE, Quoc. Efficientnet: Rethinking model scaling for convolutional neural networks. In: **International conference on machine learning**. PMLR, 2019. p. 6105-6114.

KHAN, SanaUllah et al. A novel deep learning-based framework for the detection and classification of breast cancer using transfer learning. *Pattern Recognition Letters*, v. 125, p. 1-6, 2019.

KRETZ, T. et al. Determination of contrast-detail curves in mammography image quality assessment by a parametric model observer. **Physica medica**, v. 62, p. 120-128, 2019.

KRETZ, Tobias et al. Mammography image quality assurance using *deep learning*. **IEEE Transactions on Biomedical Engineering**, v. 67, n. 12, p. 3317-3326, 2020.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. *Deep learning*. **nature**, v. 521, n. 7553, p. 436-444, 2015.

- LEE, Y.; TSAI, D.-Y.; SHINOHARA, N. Computerized quantitative evaluation of mammographic accreditation phantom images. **Medical Physics**, v. 37, n. 12, p. 6323–6331, 2010.
- LIU, T. et al. Automated detection and classification of thyroid nodules in ultrasound images using clinical-knowledge-guided convolutional neural networks. **Medical image analysis**, v. 58, p. 101555, dez. 2019.
- LOPES, Uilian Kenedi. **Redes Neurais Convolucionais aplicadas ao diagnóstico de tuberculose por meio de imagens radiológicas**. 2017. 87 f. Tese (Doutorado) - Curso de Programa Interdisciplinar de Pós-Graduação em Computação Aplicada, Unisinos, São Leopoldo, 2017. Disponível em:
http://www.repositorio.jesuita.org.br/bitstream/handle/UNISINOS/6349/Uilian%20Kenedi%20Lopes_.pdf?sequence=1&isAllowed=y. Acesso em: 14 abr. 2022.
- MAGHDID, Halgurd S. et al. Diagnosing COVID-19 pneumonia from X-ray and CT images using deep learning and transfer learning algorithms. In: Multimodal image exploitation and learning 2021. SPIE, 2021. p. 99-110.
- MA, J. et al. A pre-trained convolutional neural network based method for thyroid nodule diagnosis. **Ultrasonics**, v. 73, p. 221—230, 2017.
- MA, Jun et al. Improving air quality prediction accuracy at larger temporal resolutions using deep learning and transfer learning techniques. **Atmospheric Environment**, v. 214, p. 116885, 2019.
- MACIEL, V. N. Visualizador DICOM para o auxílio em diagnóstico médico por imagem. 2016.
- MARKETPLACE, Bc. **Mammographic Accreditation Phantom**. Disponível em:
https://www.bcgroupestore.com/Diagnostic_Imaging-Gammex_156.aspx. Acesso em: 14 abr. 2022.

MORANA, H. C. P. **Identificação do ponto de corte para a escala PCL-R (Psychopathy Checklist Revised) em população forense brasileira:** caracterização de dois subtipos de personalidade; transtorno global e parcial. 2003. Tese (Doutorado em Psiquiatria) - Faculdade de Medicina, Universidade de São Paulo, São Paulo, SP, 2003.

NEMA. NATIONAL ELECTRICAL MANUFACTURERS ASSOCIATION: DICOM Homepage. 2016. Acessado em: 22/01/2022. Disponível em: <<https://www.dicomstandard.org/current>>

OGDIE, Alexis R. et al. Seen through their eyes: residents' reflections on the cognitive and contextual components of diagnostic errors in medicine. *Academic medicine: journal of the Association of American Medical Colleges*, v. 87, n. 10, p. 1361, 2012.

MEYER, Philippe et al. Survey on *deep learning* for radiotherapy. **Computers in biology and medicine**, v. 98, p. 126-146, 2018.

Quality Assurance Programme for Digital Mammography. Vienna: INTERNATIONAL ATOMIC ENERGY AGENCY, 2011.

SABINO, S. M. P. DE S. **Implantação de um programa de controle de qualidade clínico da mamografia: análise da efetividade em um programa de rastreamento mamográfico.** [s.l.] Hospital de Câncer de Barretos, 2014.

SUNDELL, V.-M. et al. Automated daily quality control analysis for mammography in a multi-unit imaging center. **Acta radiologica (Stockholm, Sweden : 1987)**, v. 60, n. 2, p. 140–148, fev. 2019.


TRUONG, Charles; OUDRE, Laurent; VAYATIS, Nicolas. Selective review of offline change point detection methods. **Signal Processing**, [S.L.], v. 167, p. 107299, fev. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.sigpro.2019.107299>.

WORLD HEALTH ORGANIZATION. **Estimated age-standardized incidence rates (World) in 2020, worldwide, both sexes, all ages.** Disponível em:

<https://gco.iarc.fr/today/data/factsheets/cancers/20-Breast-fact-sheet.pdf>>. Acesso em: 3 fev. 2021.

ANEXO

Anexo A - Documentação comprobatória de aprovação no CEP do HCPA



PARECER CONSUBSTANCIADO DO CEP

Elaborado pela Instituição Coparticipante

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Métodos computacionais para o controle de qualidade de mamógrafos a partir de imagens obtidas com objetos simuladores de mama e de parâmetros operacionais

Pesquisador: VIVIANE RODRIGUES BOTELHO

Área Temática:

Versão: 2

CAAE: 51207721.9.3001.5327

Instituição Proponente: Hospital de Clínicas de Porto Alegre

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.193.700

Apresentação do Projeto:

As informações elencadas nos campos "Apresentação do Projeto", "Objetivo da Pesquisa" e "Avaliação dos Riscos e Benefícios" foram retiradas do arquivo do projeto e das Informações Básicas da Pesquisa Métodos computacionais para o controle de qualidade de mamógrafos a partir de imagens obtidas com objetos simuladores de mama e de parâmetros operacionais PB_INFORMAÇÕES_BÁSICAS_, 1858237 de 19/12/2021.

A detecção do câncer de mama pode ser feita através do exame de mamografia, o qual é avaliado como o padrão-ouro para esta finalidade, segundo a Organização Mundial da Saúde (OMS). Como o exame tem o objetivo de detectar microcalcificações, é necessário que os mamógrafos possuam alta sensibilidade e gerem imagens com elevada resolução espacial. Por isso, tais equipamentos são regularmente submetidos a testes de controle de qualidade utilizando objetos simuladores, conforme exigências estipuladas pela Agência Nacional de Vigilância Sanitária (ANVISA), detalhadas na Resolução da Diretoria Colegiada (RDC) N° 330 IN 54 ("INSTRUÇÃO NORMATIVA N° 54, DE 20 DE DEZEMBRO DE 2019", 2019), ou no manual da International Atomic Energy Agency (IAEA) (Quality Assurance Programme for Digital Mammography, 2011). Nestes testes, os objetos

Endereço: Avenida Protásio Alves 211 5º andar Bloco C Portão 4	CEP: 90.440-000
Bairro: Rio Branco	
UF: RS	Município: PORTO ALEGRE
Telefone: (51)3359-7640	Fax: (51)3359-7640 E-mail: cep@hcpa.edu.br

HOSPITAL DE CLÍNICAS DE
PORTO ALEGRE DA
UNIVERSIDADE FEDERAL DO
RIO GRANDE DO SUL - HCPA
UFRGS



Continuação do Parecer: 5.193.700

simuladores são imageados e, neles, existem artefatos que simulam anormalidades de uma mama. Uma quantidade mínima desses artefatos deve ser visualizada na imagem para garantir a qualidade de operação do equipamento. Atualmente, esta análise é feita de forma visual, o que torna o teste de qualidade subjetivo e operador-dependente. Dessa forma, o presente estudo tem como objetivo desenvolver um software que automatize o processo de análise das imagens obtidas de objetos simuladores para o controle de qualidade de mamógrafos e correlacione com parâmetros operacionais dos mamógrafos. Serão utilizadas técnicas de processamento de imagens para destacar artefatos e técnicas de machine learning para a detecção e quantificação dessas estruturas. Cabe salientar que apenas imagens oriundas de objetos simuladores serão utilizadas neste estudo, não sendo utilizadas imagens de pacientes.

Serão utilizadas 500 imagens de objetos simuladores, armazenadas em banco de dados da instituição.

Estudo específico da área de Tecnologias da Informação Inteligente, basicamente, de caráter experimental. Trata-se do desenvolvimento de uma solução inteligente aplicada à saúde.

Objetivo da Pesquisa:

Objetivo primário:

Aplicar e aprimorar técnicas de processamento digital de imagens combinadas a técnicas de machine learning para o desenvolvimento de uma metodologia computacional de análise de imagens de objetos simuladores, parâmetros de ajuste e de calibração do equipamento para o controle de qualidade em mamógrafos.

Objetivos secundários:

1. Criar um banco de dados contendo imagens de objetos simuladores geradas rotineiramente pelo HCPA e respectivos relatórios de qualidade e novas imagens de objetos simuladores geradas especificamente para o projeto, as quais devem contemplar problemas operacionais menos frequentes;
2. Selecionar e refinar metodologias existentes na literatura para o processamento digital de

Endereço: Avenida Protásio Alves 211 5º andar Bloco C Portão 4
Bairro: Rio Branco **CEP:** 90.440-000
UF: RS **Município:** PORTO ALEGRE
Telefone: (51)3359-7640 **Fax:** (51)3359-7640 **E-mail:** cep@hcpa.edu.br

HOSPITAL DE CLÍNICAS DE
PORTO ALEGRE DA
UNIVERSIDADE FEDERAL DO
RIO GRANDE DO SUL - HCPA
UFRGS



Continuação do Parecer: 5.193.700

imagens;

3. Detectar as estruturas nas imagens do objeto simulador do ACR via machine learning;
4. Identificar as não-conformidades da imagem do objeto simulador, seguindo a regulamentação necessária;
5. Validar as abordagens proposta à partir do parecer de especialistas;
6. Incorporar a metodologia desenvolvida em um software, a fim de ser aplicada no HCPA.

Avaliação dos Riscos e Benefícios:

Riscos:

Vazamento de dados operacionais internos dos equipamentos de mamografia do Hospital de Clínicas de Porto Alegre. Cabe salientar que a pesquisa não usa dados de pacientes.

Benefícios:

Desenvolver um método que auxilie serviços de física médica em radiodiagnóstico para o controle de qualidade de imagem de equipamentos de mamografia.

Comentários e Considerações sobre a Pesquisa:

1.OBJETOS DA PESQUISA

- Imagens geradas a partir de objetos simuladores oriundos dos mamógrafos do HCPA

2.SUJEITOS DA PESQUISA

- Por se tratar de um estudo puramente simulado, não há sujeitos.

3.METODOLOGIA

Este projeto visa o desenvolvimento, aprimoramento e aplicação de metodologias para a avaliação automática da qualidade de imagens de mamografia oriundas de objetos simuladores. O objeto adotado será o modelo RMI 156 da American College of Radiology (ACR), o qual simula uma mama de 4.5 cm de espessura, composta por 50% de tecido adiposo e 50% de tecido glandular. O objeto contém seis fibras de diferentes dimensões; cinco grupos de microcalcificações com diferentes diâmetros e cinco massas com diferentes diâmetros.

3.1. OBTENÇÃO DAS IMAGENS DO OBJETO SIMULADOR: GERAÇÃO DO BANCO DE DADOS

O banco de dados será criado em parceria com o HCPA a partir de imagens oriundas de testes de qualidade de mamógrafos, que são realizados utilizando um objeto simulador de mama. Parte dos dados necessários para a geração do banco já existe, em torno de 500 imagens. Tratam-se dos

Endereço: Avenida Protásio Alves 211 5º andar Bloco C Portão 4
Bairro: Rio Branco **CEP:** 90.440-000
UF: RS **Município:** PORTO ALEGRE
Telefone: (51)3359-7640 **Fax:** (51)3359-7640 **E-mail:** cep@hcpa.edu.br

HOSPITAL DE CLÍNICAS DE
PORTO ALEGRE DA
UNIVERSIDADE FEDERAL DO
RIO GRANDE DO SUL - HCPA
UFRGS



Continuação do Parecer: 5.193.700

testes de qualidade realizados durante a rotina diária do serviço de radiodiagnóstico. Essas imagens são armazenadas no sistema do setor de radiodiagnóstico do Hospital de Clínicas de Porto Alegre, juntamente com seus respectivos relatórios de qualidade, e serão compartilhadas com os membros da equipe responsáveis pelo desenvolvimento da metodologia de análise automática. Outra parte dos dados será gerada a partir da alteração proposital de parâmetros operacionais do mamógrafo seguida do imageamento do objeto simulador, visando a representação de problemas comuns, de forma que não seja possível visualizar as estruturas de maneira correta. Isso é necessário, pois a maioria das imagens de rotina estão em conformidade com a legislação. Entretanto, para que a identificação dos objetos utilizando deep learning seja viável, é necessário que o algoritmo reconheça também o padrão das imagens de baixa qualidade.

3.2. PROCESSAMENTO DAS IMAGENS

3.3. DETECÇÃO E CONTAGEM DOS ARTEFATOS

3.4. ANÁLISE DE CONFORMIDADE

3.5. RELATÓRIO

Com o resultado obtido, ele será disponibilizado em forma de relatório, de forma que seja conveniente na prática clínica. Dessa forma, ele será avaliado por profissionais do serviço de radiodiagnóstico do Hospital de Clínicas de Porto Alegre, a fim de analisar se está adequado.

3.6. DESENVOLVIMENTO DO FRAMEWORK

As etapas anteriores serão consolidadas em um framework, em que o usuário fornecerá uma imagem e a saída será um relatório, indicando se é uma imagem conforme ou não. Vale ressaltar que esse framework será validado com o apoio de profissionais da área do HCPA. Vale ressaltar que esses profissionais deverão assinar o Termo de Compromisso Livre Esclarecido (TCLE) conforme modelo enviado juntamente com este projeto.

Considerações sobre os Termos de apresentação obrigatória:

Os documentos obrigatórios estão adequados.

Recomendações:

Sem recomendações.

Conclusões ou Pendências e Lista de Inadequações:

As pendências emitidas para o projeto no parecer N°5143630 foram respondidas pelos pesquisadores, conforme carta de respostas adicionada em 19/12/2021.

Não apresenta novas pendências.

Endereço: Avenida Protásio Alves 211 5º andar Bloco C Portão 4
Bairro: Rio Branco **CEP:** 90.440-000
UF: RS **Município:** PORTO ALEGRE
Telefone: (51)3359-7640 **Fax:** (51)3359-7640 **E-mail:** cep@hcpa.edu.br

HOSPITAL DE CLÍNICAS DE
PORTO ALEGRE DA
UNIVERSIDADE FEDERAL DO
RIO GRANDE DO SUL - HCPA
UFRGS



Continuação do Parecer: 5.193.700

Considerações Finais a critério do CEP:

- Diante do exposto, o Comitê de Ética em Pesquisa do Hospital de Clínicas de Porto Alegre, de acordo com as atribuições definidas na Resolução CNS N.º 466/2012 e na Norma Operacional CNS/Conep N.º 001/2013, manifesta-se pela aprovação do projeto de pesquisa proposto.

- O projeto está aprovado para revisão de registros de aproximadamente 500 imagens de objetos simuladores, armazenadas em banco de dados da instituição. Por se tratar de um estudo puramente simulado, não há participantes neste centro.

- Deverão ser apresentados relatórios semestrais e um relatório final.

- Eventos adversos deverão ser comunicados de acordo com as orientações da Comissão Nacional de Ética em Pesquisa - Conep (Carta Circular N.º 13/2020-CONEP/SECNS/MS). Os desvios de protocolo também deverão ser comunicados em relatórios consolidados, por meio de Notificação.

- Os projetos executados no HCPA somente poderão ser iniciados quando seu status no sistema AGHUse Pesquisa for alterado para "Aprovado", configurando a aprovação final do Grupo de Pesquisa e Pós-Graduação.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1858237.pdf	19/12/2021 19:34:04		Aceito
Outros	carta_CEP_versao2.pdf	19/12/2021 19:33:11	BERNARDO CECCHETTO	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_atualizado_versao2.pdf	19/12/2021 19:33:06	BERNARDO CECCHETTO	Aceito
Projeto Detalhado / Brochura Investigador	projeto_versao2.pdf	19/12/2021 19:32:59	BERNARDO CECCHETTO	Aceito
TCLE / Termos de Assentimento /	TCLE_atualizado.docx	27/10/2021 15:15:26	BERNARDO CECCHETTO	Aceito

Endereço: Avenida Protásio Alves 211 5º andar Bloco C Portão 4
Bairro: Rio Branco **CEP:** 90.440-000
UF: RS **Município:** PORTO ALEGRE
Telefone: (51)3359-7640 **Fax:** (51)3359-7640 **E-mail:** cep@hcpa.edu.br

Página 05 de 06

Anexo B - Documentação comprobatória de aprovação no CEP da UFCSPA

UNIVERSIDADE FEDERAL DE
CIÊNCIAS DA SAÚDE DE
PORTO ALEGRE



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Métodos computacionais para o controle de qualidade de mamógrafos a partir de imagens obtidas com objetos simuladores de mama e de parâmetros operacionais

Pesquisador: VIVIANE RODRIGUES BOTELHO

Área Temática:

Versão: 3

CAAE: 51207721.9.0000.5345

Instituição Proponente: Universidade Federal de Ciências da Saúde de Porto Alegre

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.101.074

Apresentação do Projeto:

Resposta ao Parecer Número 5.049.054 referentes ao projeto intitulado de Métodos Computacionais para o Controle de Qualidade de Mamógrafos a partir de Imagens Obtidas com Objetos Simuladores de Mama e Parâmetros Operacionais.

Objetivo da Pesquisa:

Resposta ao parecer do colegiado.

Avaliação dos Riscos e Benefícios:

Avaliação de Riscos em resposta:

"É importante ressaltar que os riscos para participação nesta pesquisa são mínimos, relacionados, apenas, ao sigilo do banco de dados de imagens de objetos simuladores que serão utilizados. O sigilo dos dados será controlado com a disponibilização do mesmo apenas para os participantes da pesquisa, sem envolvimento ou disponibilização para terceiros."- ADEQUADO

Comentários e Considerações sobre a Pesquisa:

Pesquisador informa que as alterações solicitadas nos itens b, c, d e e do Parecer Número 5.049.054 referentes ao TCLE do projeto intitulado de Métodos Computacionais para o Controle de Qualidade de Mamógrafos a partir de Imagens Obtidas com Objetos Simuladores de Mama e Parâmetros Operacionais foram realizadas, bem como

Endereço: Rua Sarmiento Leite ,245

Bairro: Sarmiento

CEP: 90.050-170

UF: RS

Município: PORTO ALEGRE

Telefone: (51)3303-8804

E-mail: cep@ufcspa.edu.br

UNIVERSIDADE FEDERAL DE
CIÊNCIAS DA SAÚDE DE
PORTO ALEGRE



Continuação do Parecer: 5.101.074

pequenos ajustes na linguagem (a).

Considerações sobre os Termos de apresentação obrigatória:

- TCLE readequado conforme recomendação deste colegiado.

Recomendações:

- Após avaliação das alterações efetuadas no estudo acima descrito, o presente Comitê não encontrou óbices quanto à implementação das mesmas.

- A pesquisa encontra-se de acordo com a Norma vigente Resolução 466/12 para Pesquisa com Seres Humanos.

- Atentar para as datas apresentadas no cronograma para qualquer necessidade de emenda/notificação. Somente poderão ser analisadas pelo CEP com data ainda vigente da pesquisa.

- A entrega dos relatórios parciais, além de obrigatórios, também subsidiam qualquer necessidade de novas solicitações referentes ao projeto.

Conclusões ou Pendências e Lista de Inadequações:

- Não há pendências ou inadequações.

Considerações Finais a critério do CEP:

De acordo com o parecer do Relator.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1790569.pdf	27/10/2021 15:18:26		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_atualizado.docx	27/10/2021 15:15:26	BERNARDO CECCHETTO	Aceito
Outros	carta_CEP.pdf	26/10/2021 23:33:33	BERNARDO CECCHETTO	Aceito
Outros	relatorio.pdf	23/09/2021 16:05:44	BERNARDO CECCHETTO	Aceito
Declaração de Pesquisadores	TCDU_TODOS.pdf	24/08/2021 10:50:31	BERNARDO CECCHETTO	Aceito
Projeto Detalhado / Brochura Investigador	projeto.docx	19/08/2021 14:42:15	BERNARDO CECCHETTO	Aceito
Declaração de	TermoDeAnuencia.pdf	19/08/2021	BERNARDO	Aceito

Endereço: Rua Sarmiento Leite ,245
 Bairro: Sarmiento CEP: 90.050-170
 UF: RS Município: PORTO ALEGRE
 Telefone: (51)3303-8804 E-mail: cep@ufcspa.edu.br

UNIVERSIDADE FEDERAL DE
CIÊNCIAS DA SAÚDE DE
PORTO ALEGRE



Continuação do Parecer: 5.101.074

concordância	TermoDeAnuencia.pdf	14:39:16	CECCHETTO	Aceito
Folha de Rosto	folhaDeRosto_viviane.pdf	19/08/2021 14:35:50	BERNARDO CECCHETTO	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

PORTO ALEGRE, 11 de Novembro de 2021

Assinado por:
Fernanda Bordignon Nunes
(Coordenador(a))

Endereço: Rua Sarmento Leite, 245
Bairro: Sarmento CEP: 90.050-170
UF: RS Município: PORTO ALEGRE
Telefone: (51)3303-8804 E-mail: cep@ufcspa.edu.br

Página 03 de 03

Anexo C - Modelo de TCLE utilizado

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Você está sendo convidado a participar de uma pesquisa desenvolvida na Universidade Federal de Ciências da Saúde de Porto Alegre (UFCSPA), intitulada **Métodos Computacionais para o Controle de Qualidade de Mamógrafos a partir de Imagens Obtidas com Objetos Simuladores de Mama e Parâmetros Operacionais**. A pesquisa tem como objetivo desenvolver metodologias computacionais que sejam capazes de realizar, computacionalmente, o controle de qualidade de imagem em equipamentos de mamografia a partir de imagens geradas de objetos simuladores de mama. Salientamos que não serão utilizadas imagens geradas a partir de seres humanos. Este estudo se justifica pela necessidade de diminuir a subjetividade do teste de qualidade, o qual é realizado rotineiramente por profissionais de maneira visual.

Antes de aceitar a participação na pesquisa, leia atentamente as explicações abaixo sobre os procedimentos da pesquisa.

Você está sendo convidado a participar do estudo. Sua participação consiste em testar as metodologias computacionais propostas e fornecer um parecer referente ao seu potencial de utilização na prática clínica de acordo com a sua percepção. As informações fornecidas por você irão gerar dados confidenciais que serão utilizados para auxiliar no desenvolvimento de uma ferramenta de cunho tecnológico, podendo ainda serem utilizados (de forma anônima, i.e. sem sua identificação) para divulgação em eventos e/ou publicações científicas, respeitando sempre o sigilo dos participantes.

Você poderá se recusar a participar da pesquisa e poderá abandoná-la a qualquer momento, sem qualquer prejuízo.

A sua participação nesta pesquisa é voluntária, o que significa que não lhe trará nenhum privilégio, seja ele de caráter financeiro ou de qualquer natureza. Você também não terá despesas para a participação na pesquisa.

É importante ressaltar que os riscos para participação nesta pesquisa são mínimos, relacionados, apenas, ao sigilo do banco de dados de imagens de objetos simuladores que serão utilizados. O sigilo dos dados será controlado com a disponibilização do mesmo apenas para os participantes da pesquisa, sem envolvimento ou disponibilização para terceiros.

O benefício da sua participação no estudo será a contribuição para o desenvolvimento de metodologias que sejam capazes de realizar computacionalmente um processo manual de controle de qualidade de mamógrafos a partir de imagens de objetos simuladores, sem utilizar dados de pacientes, auxiliando na praticidade dos serviços de radiologia e diminuindo o caráter subjetivo desse controle de qualidade de imagem de equipamentos de mamografia.

Eventuais danos comprovadamente causados pela pesquisa serão indenizados e estarão sob responsabilidade dos pesquisadores.

O Termo de Consentimento Livre e Esclarecido é composto por duas vias, uma pertencente ao participante e outra à equipe de pesquisa. As duas vias deverão ser assinadas ao término da leitura pelo participante. Caso sejam necessários maiores esclarecimentos sobre este estudo e sua participação, você poderá entrar em contato com a pesquisadora principal Professora Dra. Viviane Rodrigues Botelho, pelo telefone (51) 3303-8871, de segunda a sexta-feira, ou pelo e-mail vivianerb@ufcspa.edu.br. Você ainda poderá entrar em contato com o Comitê de Ética em Pesquisa com Seres Humanos da UFCSPA (CEP/UFCSPA), situado na Rua Sarmento Leite, 245, Prédio 3, Sala 407, Porto Alegre, RS, pelo telefone (51) 3303-8804 ou pelo e-mail cep@ufcspa.edu.br ou pelo Comitê de Ética em Pesquisa do HCPA, situado na Av. Protásio Alves, 211 - Portão 4 - 5º andar do Bloco C - Rio Branco - Porto

Alegre/RS, de segunda à sexta, das 8h às 17h, telefone (51) 33596246, e-mail cep@hcpa.edu.br.

Confirmando ter conhecimento do conteúdo deste termo e que tive tempo adequado para refletir sobre o convite. A minha assinatura abaixo indica que concordo em participar dessa pesquisa, fui informado de seus objetivos e por isso dou meu consentimento.

Porto Alegre, _____ de _____ de _____

Nome e assinatura do participante

Data:

Professora Dra. Viviane Rodrigues Botelho

Pesquisadora Responsável

Data: