



**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.*

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

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.