

**INSTITUTO FEDERAL DE CIÊNCIA, EDUCAÇÃO E TECNOLOGIA DE SANTA
CATARINA - CAMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE SAÚDE E SERVIÇOS
MESTRADO PROFISSIONAL DE PROTEÇÃO RADIOLÓGICA**

NATÁLIA GRAMS

**USO DE INTELIGÊNCIA ARTIFICIAL NA MAMOGRAFIA: REVISÃO
INTEGRATIVA**

FLORIANÓPOLIS, 2025

NATÁLIA GRAMS

**USO DE INTELIGÊNCIA ARTIFICIAL NA MAMOGRAFIA: REVISÃO
INTEGRATIVA**

Dissertação apresentada ao Mestrado Profissional em Proteção Radiológica do Câmpus Florianópolis do Instituto Federal de Santa Catarina para a obtenção do diploma de Mestre.

Orientador: Flávio Augusto Penna Soares,
Orientadores: Juliana Almeida Coelho de Melo e Glauco Cardoso.

FLORIANÓPOLIS, 2025

Grams, Natália

USO DE INTELIGÊNCIA ARTIFICIAL NA MAMOGRAFIA: REVISÃO INTEGRATIVA
/ Natália Grams; orientação de Flávio Augusto Penna Soares. - Florianópolis,
SC, 2025.

170 p.

Dissertação (Mestrado) - Instituto Federal Santa Catarina, Campus
Florianópolis. Mestrado Profissional em Proteção Radiológica. Departamento
Acadêmico de Saúde.

Inclui referências.

1. Inteligência artificial. 2. Aprendizado de máquina. 3. Mamografia. 4.
Proteção radiológica. I. Augusto Penna Soares, Flávio. II. Instituto Federal
de Santa Catarina. III. USO DE INTELIGÊNCIA ARTIFICIAL NA MAMOGRAFIA: REVISÃO
INTEGRATIVA.

USO DE INTELIGÊNCIA ARTIFICIAL NA MAMOGRAFIA: REVISÃO INTEGRATIVA

NATÁLIA GRAMS

Este trabalho foi julgado adequado para obtenção do título de Mestre em Proteção Radiológica, pelo Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina e aprovado na sua forma final pela comissão organizadora abaixo indicada

Florianópolis, 10 de novembro, 2025

Banca Examinadora:

Prof. Flávio Augusto Penna Soares, Dr.
Orientador

Profa. Juliana Almeida Coelho de Melo, Dra
Coorientadora

Prof. Glauco Cardoso, Dr.
Coorientador

Profa. Andrea Huhn, Dra.
IFSC

Profa. Luciana Batista Nogueira, Dra.
UFMG

Prof. Alexandre D'Agostini Zottis, Dr.
IFSC

Profa. Karen Borges Waltrick, Dra.
IFSC

RESUMO

Introdução: A alta taxa da incidência do câncer de mama é uma realidade mundial, o diagnóstico precoce é uma estratégia de saúde pública, realizada por meio da mamografia. A inteligência artificial (IA) tem se mostrado um bom aliado para auxiliar o médico radiologista a diagnosticar o câncer de mama, aumentando a precisão na detecção do câncer de mama e auxiliando os profissionais da saúde a identificar sinais de anormalidades de forma mais rápida e acurada, o que pode resultar em um diagnóstico mais precoce e, consequentemente, em tratamentos mais eficazes. **Objetivo:** Avaliar a produção científica sobre a utilização da inteligência artificial em mamografia, identificando tendências, lacunas de pesquisa e implicações para a prática radiológica. **Métodos:** Foi realizada uma revisão integrativa, utilizando os bancos de dados Pubmed, BVS e Web Of Science, com os descritores “artificial intelligence”, “machine learning”, “mammography”, foram incluídos artigos publicados nos últimos 5 anos, com o idioma em inglês, com o tema relacionado a inteligência artificial na mamografia ou tomossíntese, foram excluídos artigos que realizaram pesquisa com mamografia em conjunto com outros métodos por imagem e artigos de revisão de literatura. Foram selecionados 135 artigos **Resultados:** Os países com maiores publicações foram Estados Unidos, Índia e Reino Unido. Já os fabricantes mais citados foram Hologic, GE e Siemens. Observou-se ainda que 111 trabalhos se concentraram exclusivamente em mamografia digital, enquanto 15 combinaram mamografia e tomossíntese. Foram identificados 22 bancos de dados prontos disponíveis para criação de IA e 9 publicações tiveram objetivo de desenvolver um banco de dados. 19 estudos compararam o desempenho da IA com o médico radiologista na detecção e classificação de achados mamográficos através de métricas (AUC, acurácia, sensibilidade, especificidade, VPP e VPN). Foram mapeadas as principais tendências de pesquisa no campo da IA em mamografia, classificando os estudos conforme o foco do desenvolvimento, a fim de identificar lacunas de conhecimento e recomendar futuras direções para pesquisas mais clinicamente relevantes, foram analisados 102 artigos identificando o tema central e suas métricas. Com o resultado desta dissertação, o produto tecnológico construído foi um material instrucional para desenvolver IA em mamografia. **Conclusão:** A comparação entre IA e médicos radiologistas evidencia uma tendência de integração colaborativa, em que a IA atua como ferramenta de suporte clínico e segunda leitura, e não como substituta do profissional. Sobre os bancos de dados foi identificado avanços significativos na criação e utilização de bancos de dados para IA em mamografia, persistem limitações quanto à diversidade étnica, padronização e transparência metodológica. A predominância de bases de países desenvolvidos restringe a generalização dos algoritmos em contextos globais. Outro ponto relevante é que poucos estudos especificaram o uso de imagens com implantes mamários, baixa dose e mamografia com contraste, aspectos relevantes para a aplicabilidade clínica ampla.

Palavra-chaves: Inteligência artificial. Aprendizado de máquina. Mamografia. Proteção radiológica

ABSTRACT

Introduction: The high incidence rate of breast cancer is a global reality, and early diagnosis is a public health strategy carried out through mammography. Artificial intelligence (AI) has proven to be a valuable ally in assisting radiologists in diagnosing breast cancer, increasing the accuracy of breast cancer detection and helping healthcare professionals identify signs of abnormalities more quickly and accurately, which can result in earlier diagnosis and, consequently, more effective treatments.

Objective: To evaluate scientific production on the use of artificial intelligence in mammography, identifying trends, research gaps, and implications for radiological practice. **Methods:** An integrative review was conducted using the PubMed, BVS, and Web of Science databases, with the descriptors “artificial intelligence,” “machine learning,” and “mammography.” Articles published in the last five years in English on the topic of artificial intelligence in mammography or tomosynthesis were included. Articles that conducted research with mammography in conjunction with other imaging methods and literature review articles were excluded. A total of 135 articles were selected. **Results:** The countries with the most publications were the United States, India, and the United Kingdom. The most cited manufacturers were Hologic, GE, and Siemens. It was also observed that 111 studies focused exclusively on digital mammography, while 15 combined mammography and tomosynthesis. Twenty-two ready-made databases available for AI creation were identified, and nine publications aimed to develop a database. Nineteen studies compared the performance of AI with that of radiologists in the detection and classification of mammographic findings using metrics (AUC, accuracy, sensitivity, specificity, PPV, and NPV). The main research trends in the field of AI in mammography were mapped, classifying the studies according to their development focus in order to identify knowledge gaps and recommend future directions for more clinically relevant research. A total of 102 articles were analyzed, identifying the central theme and its metrics. As a result of this dissertation, the technological product developed was instructional material for developing AI in mammography. **Conclusion:** The comparison between AI and radiologists shows a trend toward collaborative integration, in which AI acts as a clinical support tool and second reader, rather than a substitute for professionals. Regarding databases, significant advances were identified in the creation and use of databases for AI in mammography, but limitations persist in terms of ethnic diversity, standardization, and methodological transparency. The predominance of databases from developed countries restricts the generalization of algorithms in global contexts. Another relevant point is that few studies have specified the use of images with breast implants, low dose, and contrast mammography, which are relevant aspects for broad clinical applicability.

Keywords: Artificial intelligence. Machine learning. Mammography. Radiation protection

LISTA DE ILUSTRAÇÕES

Figura 1- Anatomia da superfície da mama.....	18
Figura 2- Parênquima mamário.....	19
Figura 3- Representação espacial das taxas de incidência de neoplasia maligna da mama, por 100 mil mulheres, ajustadas por idade, pela população mundial, estimadas para cada ano do triênio de 2023 a 2025, segundo Unidade da Federação.....	20
Figura 4- Processo de produção da imagem na mamografia	22
Figura 5: Critérios de avaliação de posicionamento em CC	24
Figura 6- Critérios de avaliação no posicionamento em MLO	24
Figura 7- Mamografias com implantes	25
Figura 8- Mamografia com implante menos radiodenso (composição de salina).....	26
Figura 9: Mamografia com implante de lúmen duplo composto por salina e silicone.....	26
Figura 10- Mamografia com implante de lúmen único composto por silicone).....	27
Figura 11- Mamas são quase inteiramente gordurosas.....	28
Figura 12- Áreas dispersas de densidade fibroglandular.....	28
Figura 13- Mamas são heterogeneamente densas.	29
Figura 14- Mamas são extremamente densas	29
Figura 15- Formato Nódulos	30
Figura 16- Contorno do nódulo.....	31
Figura 17- Limites na forma dos nódulos	31
Figura 18- Densidade do nódulo.	31
Figura 19- Fluxograma categoria BIRADS	32
Figura 20- Representação esquemática do processo de Aprendizado de Máquina e Aprendizado Profundo na análise de imagens mamográficas.	34
Figura 21: Fluxograma- Processo radiômico	38
Figura 22: Abstração de imagem digital	41
Figura 23– Histograma referente à imagem original de mamografia	44
Figura 24 - Processo de seleção de artigos	46
Figura 25: Fluxograma critérios de inclusão e exclusão	47
Figura 27: Quantidade de publicações por ano	50
Figura 29: Quantidade de artigos por Modalidade de imagem	52
Figura 30: Fabricantes usados nos artigos.....	53
Figura 31: Fluxograma da identificação dos bancos de dados	55
Figura 32 - Incidência de citações de banco de dados prontos indicando o país que ele foi desenvolvido	57
Figura 33: Número de imagens e centros de coleta por autor.	58
Figura 34: Período de coleta de imagens.....	61
Figura 35 - Quantidade de participação dos Radiologistas.....	73
Figura 36: Objetivos da IA em Mamografia	76
Figura 37: O processo de extração de características do conjunto de dados de imagens de câncer de mama.	80
Figura 38: Análise experimental do modelo EHA-LNN para detecção de câncer de mama	85

Figura 39 : Pré-processamentos para remoção de artefatos e ruídos	87
Figura 40- Exemplo de anotações de microcalcificações suspeitas em projeção CC.....	89
Figura 41: Resultados do conjunto de dados CBIS-DDSM com segmentação semântica dilatada ignorada e sem fator de dilatação.....	92
Figura 42: Exemplo de imagem com marcações de IA e CADe em uma paciente sem câncer	96
Figura 43: Metodologia para prever o risco de câncer de mama	100
Figura 44: Arquitetura multicanal proposta para classificação da densidade mamária .	103
Figura 45 : Exemplos de casos mostrando a distorção arquitetural típica.	107
Figura 46: Objetivos de outras categorias IA em mamografia	109
Figura 47: Exemplo de detecção quantitativa completa da mama:	114
Figura 48: Ilustração mamográficas das três classes BI-RADS definidas:.....	115

LISTA DE TABELAS

Tabela 1: Sinais Radiológicos Nódulos	30
Tabela 2: Tipos de de IA e suas aplicações	35
Tabela 3- Exemplos de CNNs em mamografia	36
Tabela 4: Critérios de inclusão e exclusão	45
Tabela 5 - Desenvolvimento de Banco de dados	55
Tabela 6 - Modelos de IAs utilizados na construção de banco de imagens	62
Tabela 7: Métricas de avaliação do modelo de IA	66
Tabela 9: Métricas comparação IA com Radiologista	69
Tabela 10: Classificação Câncer de mama	77
Tabela 11: Detecção câncer de mama	81
Tabela 12- IAs dedicadas a Microcalcificações	88
Tabela 13: IAs dedicadas as massas mamárias	89
Tabela 13: Comparação entre IAs	94
Tabela 14: IAs desenvolvidas para prever o câncer de mama	97
Tabela 15 - IAs na identificação de densidade mamária	100
Tabela 16: IAs na identificação da distorção arquitetural	105
Tabela 17 - Segmentação para construção de IA	107
Tabela 18 - Outras categorias de IAs em mamografia	109

LISTA DE ABREVIATURAS E SIGLAS

BIRADS- *Breast Imaging Reporting and Data System* (Sistema de Relatórios e Dados de Imagem Mamária)

CAD - Detecção Auxiliada por Computador

CC - Crânio-Caudal

CNES - Cadastro Nacional de Estabelecimentos de Saúde

CNN - *Convolutional Neural Networks* (Rede Neural Convolucional)

DL - *Deep Learning* (Aprendizado profundo)

DR – *Direct Radiography* (Radiografia Direta)

DSC - Dice Similarity Coefficient (Coeficiente de Similaridade de Dice)

FDA - *Food and Drug Administration* (Administração de Alimentos e Medicamentos)

GANs- Generative Adversarial Networks (arquiteturas generativas adversariais)

IA - Inteligência Artificial

IAEA - *International Atomic Energy Agency* (Agência Internacional de Energia Atômica)

IARC - Agência Internacional de Pesquisa em Câncer

ICRP - *International Commission of Radiation Protection* (Comissão Internacional de Proteção Radiológica)

ICRU - *International Commission of Radiation Units* (Comissão Internacional de Unidades e Medidas)

IFSC - Instituto Federal de Santa Catarina

IoT- *Internet of Things* (Internet das Coisas)

INCA - Instituto Nacional do Câncer

ML - *Machine Learning* (Aprendizado de máquina)

MLO - Médio Lateral Oblíquo

MS - Ministério da Saúde

RNN - Redes Neurais Recorrentes

ROI - Regions of Interest (Região de Interesse)

RSNA - *Radiologic Society of North America* (Sociedade Radiológica da América do Norte)

SVM - Support Vector Machine (máquina de Vetores de Suporte)

VPP - Valor Preditivo Positivo

VPN -Valor Preditivo Negativo

SUMÁRIO

.....	3
1. INTRODUÇÃO	13
1.1 Justificativa	15
1.2 Pergunta de pesquisa	16
1.3 Objetivo geral	16
1.4 Objetivo específico	16
2 REVISÃO DE LITERATURA	17
2.1 Anatomia da mama	17
2.2 Câncer de Mama.....	19
2.4 Mamografia Digital	21
2.4.1 Técnicas mamográficas de rotina.....	23
2.4.2- Técnica mamográfica para pacientes com implante mamário	25
2.5- Características radiológicas do tecido mamário	27
2.5.1 Sinais Radiológicos Nódulos	29
2.6. Categoria BIRADS	32
2.8. Inteligência Artificial.....	32
2.8.1- Redes Neurais Convolucionais	35
2.8.3 - Radiômica	37
2.8.4- Detecção Assistida por Computador (CAD)	39
2.9 Processamento de imagem.....	39
2.9.1 - Segmentação.....	41
2.9.2- Segmentação baseada em bordas.....	41
2.9.3 Segmentação baseada em regiões	42
2.9.4 - Extração de Características/ Atributos	43
2.9.5 - Histograma.....	43
3 METODOLOGIA.....	45
3.1- Aspectos Éticos	48
4. RESULTADOS	49
4.1.1 - Análise da quantidade de publicações por ano	49
4.1.2 - Contribuição dos países	50
4.1.3 - Modalidade de imagem (Mamografia e Tomossíntese)	52
4.1.4- Fabricantes mais citados.....	52
4.2- Banco de Dados	54
4.2.1 - Banco de dados prontos.....	56
4.2.2 - Desenvolvimento de Banco de Dados.....	58
4.2.3 - Análise demográfica em relação aos países	60
4.2.4 - Tempo de coleta de imagens	61
4.2.5 - Modelos de IAs na construção de banco de dados	62
4.3. Comparação entre IA e Radiologista.....	65
4.3.1. Participação dos Radiologistas.....	72
4.4. Tendências de pesquisa no campo da IA em mamografia	75

4.4.1. IAs para Classificação do Câncer de mama	77
4.4.2. Detecção Câncer de Mama	80
4.4.3. Desenvolvimento IA para massas mamárias	89
4.4.4- Comparação entre IAs	93
4.4.5. IAs para prever o risco do câncer de mama	97
4.4.6 - IAs na avaliação de densidades mamárias.....	100
4.4.7 - Detecção da distorção arquitetural	104
4.4.8 - Segmentação para desenvolver IAs em mamografia	107
4.4.9 - Outras categorias de IAs	108
5. CONCLUSÃO.....	118
ANEXO 1 - MANUSCRITO.....	141
1. INTRODUÇÃO	143
2 METODOLOGIA.....	144
3. RESULTADOS	146
4. CONCLUSÃO.....	156
5 REFERÊNCIAS	159
ANEXO 2 - PRODUTO TECNOLÓGICO.....	163

1. INTRODUÇÃO

Segundo a Organização Mundial da Saúde (OMS), o câncer de mama foi responsável por causar 685.000 mortes no mundo inteiro em 2020. [1]. No Brasil, com exceção do câncer de pele não melanoma, o câncer de mama é o que mais causa morte entre as mulheres. As estratégias encontradas para aumentar a sobrevida é a detecção precoce, a mamografia é o único método que associada a programas de rastreamento, apresenta eficácia comprovada para a diminuição da mortalidade [2].

A inteligência artificial (IA) tem se mostrado um bom aliado para auxiliar o médico radiologista a diagnosticar o câncer de mama. Segundo o documento “Considerações regulatórias sobre inteligência artificial para a saúde” da Organização Mundial da Saúde (OMS), a IA é caracterizada como uma área da ciência da computação, estatística e engenharia que utiliza algoritmos ou modelos para realizar tarefas e mostrar comportamentos, como aprender, tomar decisões e fazer previsões. A IA possui subconjuntos, um dos principais é conhecido como Machine Learning (ML) ou seja, Aprendizado de Máquina. Este permite que algoritmos de computador aprendam por meio de dados, sem a necessidade de programação explícita para desempenhar uma função específica. Com a crescente disponibilidade de dados sobre cuidados de saúde e o rápido progresso em técnicas analíticas, a IA apresenta um potencial significativo para revolucionar o setor da saúde, um dos pilares fundamentais para o bem-estar social e o desenvolvimento econômico global [3].

Uma preocupação da OMS é que essas tecnologias de IA estão sendo implantadas muito rápido, em algumas vezes, sem uma compreensão completa de como podem funcionar, o que podem trazer benefícios ou malefícios aos usuários finais [1].

Em outubro de 2025, o Ministério da Saúde (MS) atualizou a idade para o rastreamento do câncer de mama pelo SUS, a mamografia será realizada a partir dos 40 anos, o que promove uma maior demanda no diagnóstico dos médicos radiologistas em mamografia [4]. A IA pode ser uma ferramenta de auxílio ao médico radiologia nesse cenário de alta demanda. Este estudo tem por objetivo analisar a produção científica sobre a utilização da IA em mamografia, identificando tendências, lacunas de pesquisa e implicações para a prática radiológica, através de uma Revisão Integrativa nas bases de dados Pubmed, Web Of Science e BVS, na utilização da IA

para diagnosticar câncer de mama, identificando oportunidades para melhorias na precisão e confiabilidade do diagnóstico precoce.

1.1 Justificativa

A introdução da IA na mamografia promete otimizar o fluxo de trabalho radiológico, reduzir a carga de trabalho dos especialistas e, potencialmente, melhorar a acurácia diagnóstica, diminuindo taxas de reconvocação e falsos negativos. Contudo, a integração desses sistemas na prática clínica diária levanta questões sobre sua confiabilidade, usabilidade e custo-benefício. Este estudo se justifica por oferecer uma avaliação pragmática das evidências de comparação entre IA e radiologista, buscando entender não apenas se a IA é eficaz, mas como ela pode ser melhor empregada (como segunda leitura, sistema de triagem, ou foco em subtipos específicos de achados). A identificação de oportunidades de melhoria e limitações visa subsidiar a tomada de decisão por gestores de saúde e radiologistas sobre a adoção responsável e efetiva dessas tecnologias, visto que com a nova atualização do Ministério da Saúde no programa rastreamento do câncer de mama a partir dos 40 anos no Brasil [4], representa um aumento significativo na rotina dos médicos radiologistas.

Um dos principais desafios para a translação clínica da IA em mamografia é a validação externa e a generalização dos modelos. A maioria dos algoritmos é treinada e validada em *datasets* específicos, muitas vezes de uma única instituição ou região, o que levanta preocupações sobre o viés de dados e o desempenho em populações demográfica e etnicamente diversas. A análise dos bancos de dados utilizados justifica-se pela compreensão da diversidade e o tamanho desses *datasets*, identificando se há uma tendência à sobre-representação de certos grupos ou achados. Esta análise é essencial para apontar a principal limitação atual da pesquisa em IA mamográfica, a homogeneidade dos dados de treinamento, e estabelecer a necessidade de bancos de dados colaborativos e multiétnicos como caminho crucial para a implementação segura e equitativa da IA.

1.2 Pergunta de pesquisa

Como a produção científica tem abordado a utilização da inteligência artificial em mamografia e quais tendências emergem dessa literatura?

1.3 Objetivo geral

Analisar a produção científica sobre a utilização da inteligência artificial em mamografia, identificando tendências, lacunas de pesquisa e implicações para a prática radiológica.

1.4 Objetivo específico

- Verificar os principais bancos de dados disponíveis para criação de IA.
- Comparar o desempenho diagnóstico da IA com o do médico radiologista na detecção e classificação de achados mamográficos.
- Desenvolver um material instrucional para o desenvolvimento de modelos de IA aplicados à mamografia.

2 REVISÃO DE LITERATURA

Para subsidiar a pesquisa, foi necessário um aprofundamento teórico acerca do tema proposto a partir de livros, teses, monografias, artigos indexados em base de dados (CAPES, *Pubmed*, *Web of Science*, *Scielo*),

Neste primeiro momento, com intuito de alcançar os objetivos da pesquisa, é relevante compreender de forma clara e objetiva, o que é câncer de mama e como é diagnosticado, contextualização da mamografia, quais são os tipos de IA e como funcionam no diagnóstico auxiliar do câncer de mama.

2.1 Anatomia da mama


A mama masculina e feminina ao nascimento possui um comportamento similar. Na puberdade a mama feminina se desenvolve pelo recebimento de hormônios, enquanto a mama masculina não se desenvolve. A mama feminina adulta tem a capacidade de funcionar como um órgão produtor de leite enquanto na menopausa, o parênquima glandular começa a ser substituído por tecido adiposo [5].

O formato e o tamanho das mamas dependem de alguns fatores, como a genética, idade, número de partos e estado da menopausa. [5]. A função primária da glândula mamária é a secreção de leite, e o tamanho da mama ou quantidade de tecido glandular e gordura não influenciam na funcionalidade da glândula mamária [6].

A localização do tecido mamário se sobrepõe à cartilagem costal próxima ao esterno em direção a axila, conhecida como cauda da mama ou prolongamento axilar, e é o local com maior incidência do câncer de mama [5]. A mama média se estende da região anterior da segunda costela, próximo à clavícula, até a sexta ou sétima costela, no meio do esterno [6].


A anatomia superficial da mama, vista na Figura 1, consta com o mamilo que contém cerca de 15 a 20 aberturas de ducto de glândulas secretoras dentro do tecido da mama. A aréola é uma área circular, de pigmento escuro que envolve o mamilo junto com as Glândulas de *Montgomery* que são pequenas glândulas oleosas que tem o objetivo de manter o mamilo lubrificado e protegido, principalmente durante amamentação. A região onde a junção da parte inferior da mama com a parte anterior da parede do tórax é chamada de sulco inframamário[6].

Figura 1- Anatomia da superfície da mama



Fonte: [6]

A mama se encontra sobre a fáscia peitoral profunda, esta recobre os músculos peitoral maior e serrátil anterior na região mais acima, e na região mais abaixo o músculo oblíquo externo do abdome e sua aponeurose [5]. Conforme apresentado na Figura 2, a mama é composta pela glândula, também conhecida de parênquima mamário, onde se encontram os ductos e lobos. Gordura que envolve toda a mama e se divide em camada adiposa anterior e camada adiposa posterior e elementos fibrosos tem o objetivo de sustentar a mama [7]. A região terminal dos lóbulos, são chamadas de alvéolos, tem a finalidade funcional de secretar o leite da mama, e que possivelmente pode dar origem a lesões malignas primárias no interior da mama. Os lobos se entrelaçam em três dimensões e se misturam em suas margens. O estroma de tecido conjuntivo que envolve os lóbulos é denso e rico em fibras colágenas, e o tecido conjuntivo dentro do lóbulo é formado por uma textura frouxa que permite a rápida expansão do tecido secretor durante a gravidez. Os ligamentos de Cooper são responsáveis pela sustentação da mama, são geralmente bem desenvolvidos na parte superior da mama e ajudam a manter seu formato [5].

Figura 2- Parênquima mamário


Fonte: [8]

Na região axilar existem cerca de 20 a 30 linfonodos axilares, responsáveis por drenar a linfa de todo o membro superior, mama e tronco acima do umbigo. Podem ser divididos em cinco grupos que são: lateral, anterior (peitoral), posterior (subescapular), central e apical [5].

2.2 Câncer de Mama

No Brasil, o câncer de mama configura-se como o tipo de neoplasia maligna mais incidente entre as mulheres, excluídos os tumores de pele não melanoma, com estimativa de 73.610 casos novos por ano no triênio 2023–2025, correspondendo a uma taxa ajustada de incidência de 41,89 casos por 100 mil mulheres. As maiores taxas ajustadas concentram-se nas Regiões Sul e Sudeste, conforme vista na Figura 3, especialmente nos estados de Santa Catarina (74,8) e Rio de Janeiro (70,6), evidenciando disparidades regionais significativas [9]. No que tange à mortalidade, o câncer de mama permanece como a principal causa de óbito por câncer entre mulheres, com 19.103 mortes registradas em 2022 e uma taxa ajustada de 12,3 óbitos por 100 mil mulheres. As Regiões Sul e Sudeste também lideram os índices de mortalidade, com taxas de 13,6 e 13,2, respectivamente, sendo o estado do Rio de Janeiro o que apresenta a maior taxa ajustada (15,9) [9].

Figura 3- Representação espacial das taxas de incidência de neoplasia maligna da mama, por 100 mil mulheres, ajustadas por idade, pela população mundial, estimadas para cada ano do triênio de 2023 a 2025, segundo Unidade da Federação



Fonte:[9]

Os homens estão suscetíveis a desenvolver câncer de mama, porém o risco deles é menor, cerca de entre 1% e 2% do risco comparado com o de uma mulher e 0,1% de todos os cânceres masculinos [6]. Não há recomendação clínica para a realização de mamografias de rastreamento em homens cisgênero, uma vez que essa abordagem é direcionada à população assintomática com maior risco epidemiológico, conforme diretrizes vigentes, contudo, em 2022, com o objetivo de viabilizar o registro de mamografias de rastreamento realizadas em homens trans, foi suprimida a crítica de sexo nos sistemas de informação do Sistema Único de Saúde (SUS), incluindo o Sistema de Informação do Câncer (Siscan), permitindo assim a adequada contabilização desses procedimentos [9]. Nas mamas femininas a incidência de alterações malignas é cerca de uma em dez mulheres [5]. Um caso de câncer de mama masculino ocorre para cada 150 casos de câncer de mama feminino. Porém, em virtude de ser incomum o câncer de mama entre homens, os sintomas podem não ser relacionados ao câncer tão cedo, e geralmente a doença avança para estágios

avanzados antes de ser diagnosticada [6].

Os sintomas mais frequentes são o surgimento de nódulos, geralmente são indolores, com aspecto duro e irregular, entretanto há também tumores que são de consistência branda, globosos e bem definidos. Outros sinais de câncer de mama são: edema, com aspecto a casca de laranja; retração da pele; dor; inversão da papila; hiperemia; descamação ou ulceração da papila e secreção papilar. [10].

Nódulos mamários podem ser benignos ou ou malignos. As características dos nódulos mamários malignos geralmente apresentam os sinais clínicos de estruturas adjacentes infiltrantes, formando uma massa dura e irregular com aderência da pele, fixação no músculo, infiltração da pele ou edema da pele suprajacente na pele, conhecida como aspecto de casca de laranja [5].


Quando há metástase em linfonodos axilares, a dissecação dos linfonodos pode ser realizada por ter um grande significado prognóstico e também pode influenciar nas decisões com relação a terapia. Porém, a retirada dos linfonodos axilares pode levar a problemas crônicos pós-operatórios, como dor, formação de seroma, diminuição da mobilidade do braço, sensação prejudicada e linfedema [5].

Em 2025, o Ministério da Saúde atualizou as diretrizes nacionais de rastreamento do câncer de mama, alinhando-se às práticas internacionais e ampliando o acesso à mamografia para mulheres a partir dos 40 anos de idade, mesmo na ausência de sintomas. Essa mudança representa uma flexibilização em relação à recomendação anterior, que indicava o início do rastreamento apenas a partir dos 50 anos, conforme orientações da OMS e da Agência Internacional de Pesquisa em Câncer (IARC) [4].

2.4 Mamografia Digital

O mamógrafo é composto por um gerador de alta tensão, uma torre mecânica com um braço em forma de um arco em “C”; e um painel de controle. A imagem é formada através de um feixe de raios X, (Figura 4), proveniente de uma fonte quase pontual, que incide sobre a mama comprimida. Uma fração é transmitida através do tecido mamário e registrada em um receptor de imagem, outra fração sofre um processo de espalhamento, o qual não contribuiu para a formação da imagem. A fração restante é absorvida pelos tecidos da mama e ajudam a gerar a imagem por contraste [11].

Figura 4- Processo de produção da imagem na mamografia



Fonte: [11]

A mamografia digital pode ser dividida em dois sistemas de detecção, um incorpora uma placa de fósforo fotoestimulável mantida em um cassete durante a exposição, chamada de radiografia computadorizada (CR). O outro tipo de detector digital são sistemas contendo outros tipos de detectores, (placa plana CsI com matriz de fotodiodos, selênio amorfo de placa plana com conjunto de eletrodos ou detector de contagem de fótons de varredura de *slot*), são chamados de sistemas de radiografia direta (DR ou DX) [12]. Em Santa Catarina, segundo os dados do CNES, existem cerca de 141 sistemas CR, e 54 sistemas DR [13].

A qualidade da imagem em uma mamografia, em termos físicos, é avaliada pelas seguintes características: contraste radiográfico e resolução espacial. O contraste radiográfico deve permitir a detecção das diferenças na atenuação do feixe de raios X entre tecidos normais e diferenciados. O contraste é formado na variação da atenuação dos fótons de raios X em função das diferenças nas espessuras e densidades dos tecidos mamários. Essa variação pode sofrer por flutuações aleatórias no processo de formação da imagem, que são conhecidas como ruído quântico [11].

O ruído quântico é o principal ruído encontrado nas imagens de mamografias, ele ocorre devido a variação da quantidade de fótons de raios X que são absorvidos pelo detector em determinado intervalo de tempo e está inversamente relacionado à

dose recebida pelo paciente. Esse ruído diminui o contraste entre o fundo da imagem e estruturas de interesse, o que dificulta a detecção de pequenos detalhes ou sinais. Estudos recentes demonstraram que o ruído quântico tem um papel fundamental na qualidade da imagem, de modo que acaba afetando diretamente o desempenho do médico radiologista na detecção precoce de alguma descoberta. Além disso, esse ruído tem uma influência maior do que a resolução espacial da imagem na detecção de microcalcificações e na classificação de nódulos [14].


A resolução espacial deve ser suficiente para permitir a visualização de detalhes finos associados com sinais de câncer de mama, tais como o contorno da lesão, além de microcalcificações. Em mamografia, é esperado a percepção de detalhes estruturais da ordem de 100 μm , com nível de ruído na imagem controlado, de modo a não interferir na resolução espacial e o contraste radiográfico e mantendo a dose absorvida na mama tão baixa quanto possível, mantendo a imagem de alta qualidade diagnóstica. [11].

2.4.1 Técnicas mamográficas de rotina

O rastreamento mamográfico é realizado, tradicionalmente, por meio de duas incidências básicas: Crânio-Caudal (CC) e Médio-Lateral Oblíqua (MLO), aplicadas em ambas as mamas, totalizando quatro imagens de rotina, conforme as diretrizes do Ministério da Saúde e do Instituto Nacional de Câncer (INCA), [11]. Essas incidências permitem uma cobertura anatômica ampla das estruturas mamárias, assegurando maior precisão diagnóstica na detecção precoce de lesões suspeitas.

A incidência Crânio-Caudal (CC) é realizada com o feixe de raios X direcionado verticalmente da cabeça aos pés, abrangendo toda a glândula mamária, exceto a porção axilar. Os critérios de qualidade na avaliação do posicionamento da incidência CC, são demonstradas na Figura 5: (A), parênquima mamário; (B), deve ser visualizada a camada adiposa posterior; (C), músculo grande peitoral (presente em 30% a 40% das incidências CC, devido às diferenças anatômicas entre as pacientes. [11].

Figura 5: Critérios de avaliação de posicionamento em CC



Fonte: [11]

Já a incidência Médio-Lateral Oblíqua (MLO) é considerada a mais abrangente, pois permite a observação do tecido mamário adjacente à parede torácica e da extensão axilar, regiões frequentemente acometidas por alterações malignas. Os critérios de avaliação do posicionamento da incidência MLO, são demonstrados na Figura 6, em (A) é visualizado o parênquima; em (B) a camada adiposa posterior; em (C) o músculo grande peitoral abaixo da linha do mamilo, é possível observar que ambos estão com uma angulação simétrica; e em (D) o sulco inframamário.[11].

Figura 6- Critérios de avaliação no posicionamento em MLO



Fonte: [11]


O objetivo do posicionamento é abranger a maior quantidade de glândula

mamária na radiografia e não deve haver dobras de pele ou projeções de outras partes do corpo sobre a imagem [15].

2.4.2- Técnica mamográfica para pacientes com implante mamário

A realização de mamografias em pacientes com implantes mamários representa um desafio técnico, frequentemente comprometendo a qualidade da avaliação radiológica. Para superar essa limitação, foi desenvolvida a técnica de *Eklund*, que consiste no deslocamento do implante em direção à parede torácica, seguido da tração do tecido mamário para cima e para frente, permitindo melhor compressão e, conseqüentemente, maior visualização do parênquima mamário [16]. A compressão aplicada com o implante em posição deve ser suficientemente firme para controlar seu movimento, garantindo a integridade da imagem do implante. Ressalta-se que imagens obtidas sem o deslocamento do implante não são indicadas para avaliação do tecido mamário [5].

Na Figura 7, a imagem (A) mostra a mamografia sem o deslocamento do implante; e em (B), com o deslocamento posterior do implante por meio da manobra de Eklund [18].




Fonte: [19]

A radiodensidade em mamografias com implante mamário depende da característica da prótese. Na Figura 8, é apresentado uma imagem de mamografia na com implante onde aparece menos radiodenso pois possui lúmen único composto por salina. Na região onde é evidenciado pela seta, uma válvula é mostrada como uma densidade redonda com um centro ligeiramente transparente sobreposto ao implante

[19].


Figura 8- Mamografia com implante menos radiodenso (composição de salina)



Fonte: [19]

Na Figura 9, é possível visualizar o aspecto radiológico de uma mamografia com o implante de lúmen duplo, a camada externa possui característica menos radiodensa composta por salina e a mais interna apresenta maior radiodensidade pois é composta por silicone. [19].


Figura 9: Mamografia com implante de lúmen duplo composto por salina e silicone



Fonte: [19]

O implante mamário de lúmen único composto de silicone é apresentado na Figura 10, é possível observar uma maior radiodensidade em comparação com o implante composto por salina.

Figura 10- Mamografia com implante de lúmen único composto por silicone)




Fonte: [19]

2.5- Características radiológicas do tecido mamário

Resumidamente a composição da mama é dividida em mama adiposa, o que é mais comum em mulheres mais idosas devido a lipossustituição do tecido fibroglandular conforme visualizado na Figura 11. [20]


Figura 11- Mamas são quase inteiramente gordurosas.



Fonte: [20]

Mama Fibroadiposa, onde tem 50% de tecido fibroglandular e 50% de tecido adiposo, conforme a Figura 12. [20]


Figura 12- Áreas dispersas de densidade fibroglandular



Fonte: [20]


Mama fibroglandular, que apresenta uma grande presença de tecido fibroglandular, visto na Figura 13. [20]

Figura 13- Mamas são heterogeneamente densas.



Fonte: [20]

Na Figura 14, é demonstrado as mamas extremamente densas comum em pacientes mais jovens. [20]

Figura 14- Mamas são extremamente densas

Fonte: [20]

2.5.1 Sinais Radiológicos Nódulos

Segundo o relatório 85 da ICRU a precisão da mamografia na detecção do câncer, apresentou uma taxa de erro de 5% a 35%, e os motivos encontrados foram: o câncer não estava visível na imagem; [20]

- as indicações de câncer foram relatadas com muita sutileza;
- o câncer era visível na imagem, mas não descrito no laudo;
- pouca qualidade de imagem devido a fatores técnicos associados ao posicionamento do paciente ou à exposição ao raios-x;

Os nódulos devem ser analisados de acordo com o tamanho, contorno, limites e densidade conforme apresentado na Tabela 1.

Tabela 1: Sinais Radiológicos Nódulos


Análise Nódulo	Característica
Forma	Apresentam-se com forma ovalada ou arredondada
Tamanho	No caso dos nódulos ovalados, pode-se utilizar como medida o maior eixo; no caso dos nódulos arredondados, a medida representa o diâmetro.
Contorno	Podem apresentar contorno regular, lobulado, microlobulado, irregular e espiculado . A suspeita de malignidade aumenta quanto maior a sua irregularidade
Limites	Associação do nódulo com as estruturas vizinhas e podem ser definidos, parcialmente definidos ou pouco definidos. Teoricamente, limites pouco definidos, apresentam uma característica com maior

	suspeita de malignidade do que limites parcialmente definidos e limites definidos. Entretanto o limite do nódulo é mais uma consequência do tipo de mama do que uma característica intrínseca da lesão e não deve representar um critério de grande peso para indicar o grau de suspeição de um nódulo.
Densidade	Podem ser densos, isodensos ao parênquima mamário, com baixa densidade, com densidade de gordura e com densidade heterogênea. Normalmente os nódulos malignos apresentam densidade elevada, linfonodos intramamários têm densidade baixa, lipomas e cistos oleosos têm densidade de gordura e fibroadenolipomas têm densidade heterogênea

Fonte: Adaptado [15]

Na Figura 15 , a imagem A, o nódulo apresenta uma forma ovalada, em B forma arredondada


Figura 15- Formato Nódulos



Fonte: [15]

O contorno do nódulo é apresentado na Figura 16, na imagem A, o nódulo apresenta um contorno regular. Na imagem B, contorno lobulado. Em C, contorno irregular. Na imagem D, contorno espiculado. É possível observar que o grau de malignidade aumenta de acordo com a variação do contorno.

Figura 16- Contorno do nódulo




Fonte: Adaptado [15]

A Figura 17, apresenta os limites na forma dos nódulos, na imagem A, o limite

é definido, em B, o limite parcialmente definido; em C, o limite é pouco definido.


Figura 17- Limites na forma dos nódulos



Fonte: [15]

A densidade do nódulo é apresentada na Figura 18. Na imagem A, é apresentado um nódulo denso; em B, nódulo isodenso; na imagem C, nódulo com baixa densidade; em D, nódulo com densidade de gordura; e por último na imagem E, é apresentado nódulo com densidade heterogênea.

Figura 18- Densidade do nódulo.




Fonte: [15]

2.6. Categoria BIRADS

No início da década de 1990, foi desenvolvido o *Breast Imaging Reporting and Data System* (BI-RADS®), um sistema internacional destinado à padronização da avaliação mamária, da interpretação dos exames de imagem e da elaboração dos respectivos laudos. Esse sistema introduziu uma nomenclatura uniforme e critérios específicos para a classificação dos achados mamográficos. De acordo com o BI-RADS®, ao término da análise das imagens, os exames são categorizados em uma escala de 0 a 6, conforme descrito na Figura 19, sendo que cada categoria expressa o grau de probabilidade de malignidade da lesão identificada e orienta a conduta clínica recomendada para o caso. [7]

Figura 19- Fluxograma categoria BIRADS



Fonte: Adaptado [8], Napkin

2.8. Inteligência Artificial

A inteligência artificial (IA) tem se consolidado como uma ferramenta essencial no diagnóstico de patologias por meio da análise de imagens médicas. Sua aplicação em radiologia, especificamente em modalidades como mamografias, tomografias computadorizadas e ressonâncias magnéticas, têm o potencial de auxiliar na identificação precoce de doenças, reduzir erros diagnósticos e otimizar o tempo de trabalho dos profissionais de saúde [21].


Dentre as principais categorias de IA aplicadas em imagens médicas, destaca-se o aprendizado de máquina, *Machine Learning* (ML), que utiliza algoritmos capazes de identificar padrões em dados após um processo de treinamento supervisionado. Nesse contexto, sistemas são alimentados com grandes quantidades de imagens previamente rotuladas, permitindo que a IA diferencie estruturas normais de anomalias [22]

Uma subcategoria do aprendizado de máquina que tem ganhado destaque é o aprendizado profundo *Deep Learning* (DL), baseado em redes neurais artificiais com

múltiplas camadas que simulam o funcionamento do cérebro humano. Modelos de aprendizado profundo, como redes neurais convolucionais (CNNs), são amplamente utilizados no reconhecimento de padrões complexos em imagens radiológicas. Esses sistemas têm demonstrado alta sensibilidade e especificidade na detecção de patologias, como câncer de mama em mamografias [23].

A Figura 20 ilustra, de forma esquemática, o fluxo do processo de análise de imagens mamográficas por meio de técnicas de ML e DL. Inicialmente, a imagem da mamografia é submetida a um processo de extração de características (*features*), etapa fundamental para que o sistema identifique padrões relevantes associados a estruturas mamárias normais e anômalas. No contexto do ML, essas características são selecionadas e utilizadas como variáveis de entrada para algoritmos supervisionados que realizam a predição diagnóstica, distinguindo entre tecidos saudáveis, suspeitos ou malignos. O DL, por sua vez, aprofunda esse processo ao empregar redes neurais artificiais convolucionais (CNNs) capazes de aprender automaticamente as representações hierárquicas das imagens, reduzindo a necessidade de intervenção humana na seleção das características. Essa abordagem permite que os modelos processem diretamente os *pixels* da imagem, alcançando maior precisão diagnóstica e melhor desempenho em tarefas complexas, como a detecção de microcalcificações e massas [24]. Assim, a figura evidencia a evolução dos métodos tradicionais de aprendizado para arquiteturas profundas, que têm se mostrado mais eficazes na interpretação automatizada de exames mamográficos.

Figura 20- Representação esquemática do processo de Aprendizado de Máquina e Aprendizado Profundo na análise de imagens mamográficas.



Fonte: Adaptado [24]

Todos os dispositivos médicos comercializados devem ser aprovados pela *Food and Drug Administration* (FDA). Os fabricantes devem seguir as orientações da FDA e podem precisar revisar e liberar modificações nos dispositivos médicos, incluindo software como dispositivo médico, dependendo da importância ou risco representado para os pacientes dessa modificação. [25]

Existem mais de 20 aplicações de IA aprovadas pela FDA, no entanto, a admissão e o uso dessas tecnologias ainda são bastante variáveis e, em geral, permanecem baixos. Além das soluções existentes, há um vasto potencial para novas aplicações de IA, como suporte à decisão clínica, avaliação de risco, quantificação da densidade mamária, otimização do fluxo de trabalho e triagem, avaliação de qualidade, monitoramento da resposta à quimioterapia neoadjuvante e aprimoramento da qualidade das imagens [26]. A Tabela 2 apresenta uma síntese das principais aplicações de IA em imagens médicas, baseada em diversos estudos de revisão na área:

Tabela 2: Tipos de de IA e suas aplicações

Tipos de IA	Aplicação
Redes Neurais Convolucionais (CNNs)	Classificação e detecção de patologias em exames como tomografia computadorizada e ressonância magnética.
Redes Neurais Recorrentes (RNNs)	Análise de séries temporais em imagens, como variações ao longo de exames de ultrassom.
Aprendizado Profundo (Deep Learning)	Reconhecimento de padrões complexos em grandes conjuntos de dados de imagens.
Aprendizado por Reforço (Reinforcement Learning)	Treinamento de agentes para otimizar protocolos de imagem ou calibração de equipamentos.
Sistemas de Diagnóstico Assistido por Computador (CAD)	Auxílio na detecção de anomalias, como nódulos em mamografias
Segmentação de Imagens	Identificação de áreas anatômicas específicas ou lesões em imagens médicas.

Fonte: [23], [27], [28], [29], [30]

Apesar do avanço tecnológico, a implementação da IA na prática clínica ainda enfrenta desafios. Entre eles, destacam-se a necessidade de padronização de dados,

a garantia da aplicabilidade dos modelos para maior confiabilidade clínica e a integração das ferramentas de IA nos sistemas de saúde [31]. Portanto, a adoção de IA em radiologia deve ser vista como uma ferramenta complementar à expertise médica, agilizando e potencializando diagnósticos mais precisos e precoces.

2.8.1- Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNNs) constituem uma arquitetura de aprendizado profundo amplamente empregada na análise de imagens médicas, projetada para reconhecer padrões complexos em dados visuais. Essa abordagem baseia-se em camadas convolucionais, *pooling* (operação que reduz a dimensionalidade espacial dos mapas de características, preservando informações essenciais) e camadas totalmente conectadas, permitindo que as CNNs extraiam automaticamente características relevantes de imagens médicas, como mamografias, tomografias computadorizadas e ressonâncias magnéticas. Elas viabilizam diversas aplicações, incluindo classificação, segmentação e detecção de anomalias. Entre suas principais vantagens estão a alta precisão e a capacidade de generalização para grandes conjuntos de dados, tornando-as ferramentas valiosas para diagnósticos assistidos por inteligência artificial. Contudo, as CNNs apresentam desafios, como a necessidade de grandes volumes de dados rotulados para treinamento, o potencial de introdução de viés devido a dados não representativos e a dificuldade de interpretar seus resultados devido à sua natureza de "caixa-preta", o que pode limitar sua aplicabilidade clínica (SHEN et al., 2017; LITJENS et al., 2017). [28]; [23]. Na Tabela 3, estão descritos exemplos de CNNs encontrados na literatura.

Tabela 3- Exemplos de CNNs em mamografia

Tipo de CNN	Conceito	Aplicação
Rede Neuronal Convolucional Clássica	Arquitetura básica composta por camadas convolucionais, pooling e totalmente conectadas, usada para extração e classificação de características.	Detecção de lesões suspeitas em mamografias.
Rede Residual (ResNet)	Inclui conexões residuais que permitem o aprendizado de mapas de características mais profundos, mitigando o problema de gradientes	Classificação de densidade mamária e identificação de anomalias.

	desaparecendo.	
Rede de Convolução Densa (DenseNet)	Conecta cada camada a todas as camadas subsequentes, promovendo o reaproveitamento de características e a redução do overfitting.	Análise de padrões complexos para diagnósticos em mamografias digitais.

Fonte: Adaptado [32]; [33]; [34]; [35]; [23]; [36]

2.8.2 - Redes Neurais Recorrentes (RNNs)

As redes neurais recorrentes são uma classe de redes neurais especialmente desenvolvidas para processar dados sequenciais ou temporais, permitindo que informações de etapas anteriores influenciam o processamento das etapas subsequentes. Essa capacidade torna as RNNs particularmente adequadas para aplicações em imagens médicas que envolvem séries temporais, como a análise de variações em ultrassonografias ao longo do tempo ou estudos funcionais de ressonância magnética. Ao contrário das Redes Neurais Convolucionais (CNNs), que são focadas na análise de padrões espaciais em imagens estáticas, as RNNs capturam relações temporais, tornando-as mais apropriadas para cenários em que a sequência dos dados é essencial. Enquanto as CNNs predominam em tarefas como classificação e segmentação, as RNNs complementam essas aplicações ao serem utilizadas em previsões de progressão de doenças ou na análise de séries temporais de exames médicos, ampliando o potencial da inteligência artificial em saúde [27].

As RNNs na mamografia são cada vez mais reconhecidas por sua capacidade de melhorar a detecção do câncer de mama por meio da análise de padrões temporais em dados de imagem. Os RNNs, particularmente quando combinados com CNNs, podem capturar com eficácia as características dinâmicas das imagens mamográficas, melhorando a classificação dos tumores como benignos ou malignos. Os RNNs também podem enfrentar os desafios associados a conjuntos de dados desequilibrados, um problema comum na mamografia, reconhecendo padrões que podem ser ignorados pelos métodos tradicionais [36]. No geral, a integração de RNNs na análise mamográfica representa um avanço promissor na busca por diagnósticos confiáveis e eficientes do câncer de mama [37]; [38].

2.8.3 - Radiômica

A radiômica é uma abordagem que permite a extração de características quantitativas em grande escala a partir de imagens médicas, com o intuito de

transformar dados radiológicos em informações estruturadas e mineráveis, ou seja, organizadas em variáveis numéricas padronizadas, passíveis de armazenamento em bases de dados e de análise por métodos estatísticos e algoritmos de mineração de dados, contribuindo para análises mais detalhadas e precisas no campo da radiologia [39]. A radiogenômica representa a aplicação abrangente da radiogenética, com foco na identificação das bases genéticas responsáveis pela variação individual na sensibilidade à radiação. Estudos indicam um consenso crescente de que a radiosensibilidade é uma característica complexa, poligênica e hereditária, resultante da interação de múltiplos genes envolvidos em diversos processos celulares[40]

O processo radiômico pode ser estruturado em cinco etapas principais, cada uma com entradas e saídas bem definidas, bem como desafios específicos que necessitam ser superados: (a) aquisição e reconstrução de imagens, (b) segmentação e renderização de imagens, (c) extração e qualificação de características, (d) armazenamento e compartilhamento em bancos de dados e (e) análises informáticas específicas [41]. As etapas seguem os passos da Figura 21:

Figura 21: Fluxograma- Processo radiômico



Fonte: Adaptado [41], Napkig

O método de IA radiômica, consiste em focar na extração e análise de características quantitativas avançadas diretamente de imagens médicas, difere de outros métodos de IA em imagens médicas, como as CNNs e os sistemas de CAD. Enquanto as CNNs geralmente se concentram na classificação automática e na detecção de padrões em imagens usando aprendizado profundo, a radiômica busca correlacionar dados de imagens com informações clínicas e biológicas, fornecendo *insights* mais interpretáveis e específicos sobre o fenótipo do paciente. Por outro lado, os sistemas CAD auxiliam radiologistas ao destacar possíveis áreas de interesse, mas carecem da profundidade analítica da radiômica em identificar biomarcadores prognósticos e preditivos. Em suma, a radiômica complementa essas abordagens ao combinar análise quantitativa detalhada com integração clínica, oferecendo um caminho promissor para a personalização da medicina [42]; [28].

2.8.4- Detecção Assistida por Computador (CAD)

A Detecção Auxiliada por Computador (CAD) é uma tecnologia que surgiu em 1967, com o objetivo de usar os computadores para localizar as regiões suspeitas, porém até a década de 1980, essa tecnologia tinha pouca acurácia em relação a interpretação dos radiologistas. Na década de 1990, técnicas mais avançadas de processamento de imagens foram implementadas, permitindo obter resultados um pouco mais consistentes nessa área. Nos últimos anos, houve uma grande evolução dessa ferramenta, fazendo com que esses esquemas começassem a ser aplicados em diferentes campos da radiologia [14].

Na mamografia, essa tecnologia tem a finalidade de utilizar algoritmos de detecção computadorizados para analisar imagens digitais e auxiliar no diagnóstico de lesões suspeitas, calcificações anormais e distorções de parênquima. A avaliação do médico radiologista continua sendo a principal, a ferramenta CAD tem por objetivo auxiliar na avaliação de áreas suspeitas, por exemplo, aglomerados de microcalcificações porque diferem de estruturas anatômicas normais em densidade, tamanho e forma. [5]

O CAD é dividido em duas classificações: CAdE e CADx. O CAdE (*Computer-Aided Detection*) tem como função primordial localizar automaticamente regiões suspeitas em imagens médicas, como microcalcificações ou massas, atuando como um suporte à detecção inicial de anomalias, sem emitir um diagnóstico definitivo. Por outro lado, o CADx (*Computer-Aided Diagnosis*) é projetado para analisar, caracterizar e classificar essas lesões, auxiliando o radiologista na distinção entre achados benignos e malignos, além de estimar a probabilidade de câncer. Assim, o CAdE exerce um papel de triagem e marcação de áreas de interesse, enquanto o CADx desempenha uma função interpretativa e decisória, oferecendo suporte clínico mais avançado. O CAdE funciona como uma segunda leitura para destacar áreas suspeitas, enquanto o CADx fornece uma avaliação diagnóstica mais detalhada [43]. Essa diferenciação é fundamental, pois expressa distintos níveis de complexidade algorítmica e influência no processo diagnóstico, ao evidenciar que ambos os sistemas, quando integrados, podem potencializar a precisão e a eficiência do diagnóstico por imagem. [44]

2.9 Processamento de imagem

O processamento de imagem, especialmente na etapa de remoção do fundo em mamografias, desempenha um papel crucial na análise automatizada por IA, facilitando a identificação de regiões de interesse. Um método amplamente utilizado nesse contexto é a limiarização, que consiste em segmentar a imagem ao converter os pixels em valores binários com base em um limiar predefinido. Esse processo separa o tecido mamário do fundo, eliminando artefatos ou áreas irrelevantes que podem prejudicar a análise. A limiarização não apenas melhora a qualidade da imagem para algoritmos de aprendizado profundo, como também reduz o tempo de processamento e a complexidade computacional, tornando os sistemas de diagnóstico mais eficientes. Essa etapa serve como um método inicial em pipelines mais complexos, isto é, fluxos encadeados de processamento que organizam, em etapas sucessivas, o pré-processamento, a segmentação, a extração de características e, por fim, a classificação automatizada. Nesses pipelines, costumam ser integradas CNNs para classificação e detecção de anomalias em mamografia. Estudos destacam que a remoção precisa do fundo melhora a acurácia de sistemas baseados em inteligência artificial, contribuindo para diagnósticos mais confiáveis [45].

O processo baseia-se em um valor pré-definido chamado limiar, onde os valores maiores ou iguais ao limiar se tornam 1, caso contrário recebe 0, como na Equação 1.

Equação 1: Binarização da imagem


$$B(x, y) = \begin{cases} 1, & \text{Se } I(x, y) \geq \text{limiar} \\ 0, & \text{Caso contrário} \end{cases}$$

Fonte: [45]

Após a binarização da imagem, o resultado é utilizado para multiplicar os valores reais da imagem original. Nesse processo, os pixels binarizados com valor 1 mantêm seus valores originais, enquanto os demais são redefinidos como 0, eliminando efetivamente o fundo da imagem, conforme demonstrado na Figura 22. Essa operação ajusta a matriz de valores, atribuindo 0 às áreas correspondentes ao fundo, facilitando a remoção completa desse elemento. Devido ao alto contraste em tons de cinza entre o fundo e as regiões de interesse, a separação torna-se simples e eficiente. Ao aplicar essa multiplicação pixel a pixel, utilizando a imagem binária como

máscara, obtém-se a imagem original com o fundo removido, o que é essencial para o processamento avançado e a análise automatizada por IA em mamografias. [46]

Figura 22: Abstração de imagem digital



Fonte:[46]

2.9.1 - Segmentação

A fase de segmentação no processamento de imagens mamográficas engloba a identificação e o delineamento de regiões significativas, como neoplasias, por meio da aplicação de diversas metodologias de processamento de imagens. Esse processo facilita a localização de doenças malignas, aumentando assim a precisão dos sistemas automatizados utilizados para fins de diagnóstico e formulação de estratégias de tratamento. [47]

Os métodos para segmentação de imagens são classificados em três categorias básicas: [48]

1. Limiarização (*Thresholding*);
2. Segmentação baseada em bordas;
3. Segmentação baseada em regiões.

2.9.2- Segmentação baseada em bordas

A segmentação baseada em bordas é uma técnica utilizada para identificar regiões em uma imagem onde há mudanças bruscas nos tons de cinza, que geralmente indicam limites ou contornos entre diferentes objetos na imagem. Essas

mudanças podem aparecer como pontos, linhas ou segmentos que, ao serem conectados, formam os contornos dos objetos presentes na imagem. Para identificar essas bordas, são usados algoritmos que detectam variações nos níveis de brilho da imagem, denominados operadores de derivação local. Esses operadores analisam as mudanças nos tons e determinam a direção onde essas variações ocorrem mais rapidamente. Essa informação, conhecida como gradiente, é usada para localizar as bordas na imagem. Ferramentas amplamente utilizadas nesse processo incluem operadores matemáticos como Sobel, Prewitt, Canny e Laplaciano, que funcionam como filtros aplicados à imagem para destacar as bordas. Em termos simples, esses operadores criam "máscaras" que ajudam a separar os objetos do fundo, tornando possível a segmentação da imagem de forma clara e estruturada [48].

2.9.3 Segmentação baseada em regiões

A segmentação baseada em regiões é uma técnica utilizada para dividir uma imagem em áreas com características semelhantes, como níveis de cinza ou textura, agrupando pixels que compartilham propriedades similares. Esse método funciona a partir de "sementes", que são pontos iniciais escolhidos na imagem. A partir dessas sementes, as regiões crescem agregando pixels vizinhos que atendam a critérios específicos de similaridade. O processo segue quatro passos principais: [49]

- (a) seleção das sementes, que depende do problema a ser resolvido;
- (b) definição das propriedades que determinam os critérios de similaridade, como cor ou textura;
- (c) análise de conectividade entre os pixels, considerando se estão próximos e relacionados;
- (d) aplicação de uma regra de parada para decidir quando o crescimento da região deve ser encerrado, com base em critérios como tamanho ou semelhança entre os pixels.

De maneira simples, a segmentação baseada em regiões ajuda a dividir uma imagem em áreas específicas que possuem características comuns, facilitando a análise e o processamento da imagem. Essa técnica é utilizada em diversas aplicações, como a detecção de lesões em mamografias ou a identificação de órgãos em outras modalidades por imagem, como tomografia computadorizada, promovendo resultados confiáveis e detalhados. [49]

2.9.4 - Extração de Características/ Atributos

Essa etapa consiste em identificar e isolar informações relevantes presentes na imagem, como bordas, texturas, formas e intensidades, que podem ser usadas para representar padrões específicos associados a determinadas condições clínicas. Essas características extraídas servem como entrada para algoritmos de aprendizado de máquina, permitindo que modelos inteligentes realizem tarefas como classificação, segmentação e detecção de anomalias. A qualidade das características extraídas impacta diretamente o desempenho do modelo, sendo crucial selecionar atributos que sejam representativos e discriminativos. Métodos como transformadas de *Fourier*, *wavelets*, histogramas de intensidades ou mesmo técnicas mais recentes baseadas em aprendizado profundo são amplamente utilizados nesse contexto [28]

Na análise de imagens de mamografia, a etapa de extração de características desempenha um papel essencial para a identificação de padrões associados a lesões, como nódulos ou microcalcificações. Essa fase busca capturar informações relevantes, como texturas, formas e bordas das estruturas mamárias, que podem ser usadas para treinar modelos de inteligência artificial. Por exemplo, características baseadas em histogramas de intensidades podem ajudar a diferenciar tecidos densos de regiões anômalas, enquanto atributos baseados em texturas podem ser úteis para identificar microcalcificações associadas ao câncer de mama. [28]


2.9.5 - Histograma

O histograma em imagens médicas é uma ferramenta matemática que representa graficamente a distribuição dos diferentes níveis de intensidade de cinza presentes em uma imagem, indicando quantas vezes cada nível de brilho aparece. Em termos simples, ele permite entender como os tons estão distribuídos na imagem, como áreas mais claras ou escuras, sendo uma técnica essencial para analisar o contraste e a qualidade da imagem. No desenvolvimento de sistemas de IA, o histograma é frequentemente usado para extrair características importantes que ajudam a diferenciar tecidos normais de anômalos. Por exemplo, em mamografias, as distribuições dos níveis de cinza extraídas do histograma auxiliam na identificação de padrões associados a nódulos ou microcalcificações, elementos que podem ser indicativos de câncer de mama. Técnicas como a equalização de histograma são aplicadas para melhorar o contraste da imagem, facilitando o desempenho de

algoritmos de IA em tarefas como classificação e segmentação. O uso do histograma no pré-processamento das imagens é uma etapa crucial para a construção de modelos de aprendizado profundo mais precisos e eficientes [48].

Na Figura 31, podemos verificar um exemplo do histograma da imagem original de uma imagem mamográfica, sendo que o eixo x na imagem B, apresenta o grau de cinza (densidade óptica), e o eixo y apresenta o número de pixels da imagem. Na imagem B o histograma aponta três regiões principais: a primeira é a área de predominância de tecido fibroglandular, área G, a segunda, indicada por A, representa a região de tecido 100% adiposo; e a terceira região, indicada por B, representa a borda da mama (tecido adiposo). [50]

Figura 23– Histograma referente à imagem original de mamografia



Fonte: Adaptado [50]

3 METODOLOGIA

A presente dissertação adota uma abordagem qualitativa, de natureza exploratória, com base em uma revisão integrativa da literatura, método amplamente reconhecido por permitir a síntese crítica de estudos primários, integrando diferentes abordagens metodológicas em um único corpo analítico [51]. No enfoque qualitativo de caráter exploratório, privilegia-se a abertura do delineamento, a sensibilidade ao contexto e a construção iterativa de significados a partir dos dados [52]. Como também a integração de múltiplas fontes e estratégias analíticas funciona como triangulação, elevando a validade e a profundidade interpretativa das sínteses de literatura [53].

Para isso, foi realizada uma busca sistematizada nas bases de dados BVS, *PubMed* e *Web of Science*, utilizando os descritores booleanos “inteligência artificial” OR “aprendizado de máquina” AND “mamografia”, com recorte temporal dos últimos cinco anos, (janeiro de 2019 à janeiro de 2025) publicados em inglês. O processo de triagem seguiu critérios de inclusão e exclusão previamente definidos, conforme a Tabela 4.

Tabela 4: Critérios de inclusão e exclusão

Abordagem	Critérios de inclusão	Critérios de exclusão
Relevância do tema	Artigos que abordam a aplicação da IA em mamografia e tomossíntese; banco de dados com mamografia e outros métodos por imagem	Artigos que não utilizassem IA em mamografia ou tomossíntese; artigos que desenvolveram ou compararam IA com outros métodos por imagem
Tipo de estudo	Artigos originais exploratório ou descritivo; Pesquisa Comparativa; Experimental, Pesquisa de Desenvolvimento; Pesquisa Aplicada;	Revisões sistemáticas, meta-análises e estudos de caso.
Idioma	Artigos publicados em Inglês	Todos idiomas que não foram publicados em inglês
Disponibilidade	Últimos 5 anos da publicação	Mais de 5 anos de publicação


Fonte: Da autora(2025)

Foram excluídos artigos que apresentavam IA de mamografia e tomossíntese

com outros métodos por imagem, como ultrassonografia e ressonância magnética. Somente foi incluído outros métodos por imagem na categoria “Banco de dados” para poder identificar todas as bases de dados em que os pesquisadores possam encontrar imagens prontas para aplicação de modelos de IA em pesquisas futuras.

Os artigos foram organizados em uma planilha de Excel para facilitar a categorização e análise dos conteúdos selecionados, para pesquisas de natureza integrativa [55]. Na primeira etapa, foram encontrados 193 artigos na base de dados BVS, 92 na *PubMed* e 257 na *Web of Science*, totalizando 542 artigos. Após a análise dos critérios de inclusão e exclusão, foram selecionados 135 artigos, os quais estão ilustrados na Figura 24, que apresenta tanto o número total de artigos encontrados nas bases de dados quanto a quantidade de artigos incluídos na pesquisa.


Figura 24 - Processo de seleção de artigos



Fonte: Da autora (2025) Napkin

Após a seleção, os estudos foram classificados em três categorias temáticas principais: Banco de dados, Comparação entre IA e Radiologista e Inteligência Artificial, conforme o fluxograma da Figura 25. Essa etapa seguiu os princípios da análise categorial temática, permitindo uma leitura aprofundada dos objetivos, métodos e contribuições de cada artigo. Deste modo, a revisão integrativa aqui empregada não se limita à simples descrição de evidências, mas busca interpretar e organizar os achados de modo a identificar lacunas, tendências e implicações para futuras pesquisas e aplicações clínicas da IA em imagens médicas. [55]

Figura 25: Fluxograma critérios de inclusão e exclusão



Fonte: Da autora (2025)

No contexto desta dissertação, elaborou-se um manuscrito para futura submissão a periódico científico e desenvolveu-se, como produto tecnológico, um material instrucional voltado ao desenvolvimento de modelos de IA aplicados à mamografia. O produto tecnológico serve como um guia prático, em etapas, abrangendo a seleção de bases de dados, a definição do problema, a preparação das imagens, a escolha de arquiteturas de deep learning, o treinamento e a avaliação do desempenho dos modelos, além de incorporar reflexões éticas e clínicas. Esse material foi construído a partir das evidências identificadas na revisão integrativa e estruturado para apoiar pesquisadores, estudantes e profissionais de saúde na implementação de soluções em IA para mamografia, favorecendo a reprodutibilidade dos procedimentos e a adoção de boas práticas.

3.1- Aspectos Éticos


Não foi necessário aprovação no Comitê de Ética devido a pesquisa não envolver seres humanos.

Foi utilizada IA Napkin para criação de imagens e ChatGPT 5.1 para criação de fluxogramas e correção de gramática.

4. RESULTADOS

Inicialmente identificou-se as tendências de publicações através de um panorama geral das publicações dos últimos cinco anos que abordam IA em mamografia. A análise foi separada por ano de publicações; países que tiveram maior contribuições; quantidade de estudos que utilizaram mamografia e/ou tomossíntese e fabricantes mais citados, conforme a Figura 26.

Figura 26: Fluxograma metodologia panorama geral publicações




Fonte: Da autora (2025)

Os resultados foram analisados através do software RSTUDIO versão R 4.4.1 (2024-06-14 ucrt) que possibilita a organização dos gráficos e tabelas. O RStudio é um ambiente de desenvolvimento integrado voltado para a linguagem de programação R, amplamente utilizado por cientistas de dados e estatísticos. Ele oferece uma interface amigável e recursos avançados para análise de dados, visualização gráfica e criação de relatórios dinâmicos [56].

4.1.1 - Análise da quantidade de publicações por ano

A Figura 27 apresenta a quantidade de publicações nos últimos 5 anos .

Figura 27: Quantidade de publicações por ano


Fonte: Da autora, (2025), [57], [58]

O ano que teve maior quantidade de publicações foi o ano de 2023 com 39 e o ano de 2024 com 34. O ano de 2019 teve somente 2 publicações e o ano 2025 teve 3 publicações devido a busca de artigos nos bancos de dados foram extraídas no início do ano de 2025.

4.1.2 - Contribuição dos países

Identificaram-se 27 países, havendo artigos com coautoria internacional. A frequência de colaboração por país é apresentada na Figura 28.

Figura 28: Frequência de Países



Fonte: Da autora (2025), [57], [58]


Observou-se maior participação dos Estados Unidos, com 15 ocorrências, seguidos pela Índia 9. China e Reino Unido com 5, Itália e Suécia com 4, Egito, Coreia do Sul, Austrália e Noruega com 3, Irã, Taiwan, Inglaterra, Suíça, Paquistão, Colômbia, Dinamarca, Alemanha e Turquia com 2 e Grécia, Espanha, Arábia Saudita, Finlândia, Portugal, Malásia, Áustria e México com apenas 1 participação.

A análise comparativa entre países desenvolvidos e em desenvolvimento no campo da IA aplicada à mamografia revela uma assimetria significativa na produção científica e na participação em estudos multicêntricos. Embora existam mais de 190 países reconhecidos pela Organização das Nações Unidas, apenas um número restrito, predominantemente dos Estados Unidos, Índia, Reino Unido e China, concentra a maior parte das publicações e dos bancos de dados utilizados para treinamento e validação de modelos de IA. Essa concentração geográfica da pesquisa implica que a maioria dos algoritmos foi desenvolvida com base em populações e equipamentos de países com alta disponibilidade tecnológica e infraestrutura robusta, o que limita a capacidade de generalização dos modelos quando aplicados a contextos de países menos desenvolvidos [59]. A ausência de participação de países subdesenvolvidos ou emergentes, especialmente da América Latina e da África, amplia o risco de viés algorítmico e compromete a equidade diagnóstica, uma vez que as diferenças genéticas, ambientais e de protocolos de aquisição de imagem podem afetar o desempenho dos sistemas de IA. Assim, esse resultado apresenta uma

desigualdade científica, sugerindo a necessidade de políticas de colaboração internacional e a criação de bases de dados diversificadas e multiétnicas, capazes de promover sistemas de IA mais equilibrados e que funcionem bem em diferentes países e populações.[60];[61] .

4.1.3 - Modalidade de imagem (Mamografia e Tomossíntese)

Dentre esses estudos 111 focaram somente em Mamografia, 6 artigos em Mamografia com contraste, 15 em Mamografia e Tomossíntese, 5 somente em Tomossíntese e 2 artigos criaram banco de dados com Mamografia e com outras modalidades por imagem como Ressonância Magnética e Ultrassom, conforme a Figura 29.




Fonte: Da autora (2025), [57], [58]

4.1.4- Fabricantes mais citados

Foi identificado os fabricantes de mamografia e tomossíntese mais utilizados na coleta de dados, conforme a Figura 30. Os artigos que utilizaram as imagens através de banco de imagens foram identificados como “N/A” (não se aplica), já os artigos que realizaram a coleta de imagens através de instituições e ou centro de imagens mas não especificaram qual foi o fabricante, foram identificados como “não específica”. Nesta análise foi possível observar que o Fabricante Hologic foi o mais

utilizado para a coleta das imagens em 35 artigos, em segundo lugar a GE com 26 e terceiro lugar a Siemens com 19. A Siemens foi encontrada em 19 estudos, a Philips em 12 e a Fujifilm em 10 estudos. Os fabricantes com menos participações foram a Giotto e a Sectra com 5, Kodak e Konica que hoje são a mesma empresa com 2, Agfa, Digital Mammography Sweden AB, IMS em apenas 1 estudo. Os estudos identificados como “N/A” foram encontrados 43 e “não específica” 34 estudos.

Figura 30: Fabricantes usados nos artigos



Fonte: Da autora (2025), [57], [58]

Por fim, a análise do panorama global das publicações sobre o uso da IA em mamografia evidencia um crescimento expressivo da produção científica nos últimos cinco anos, com destaque para os anos de 2023 e 2024. Observa-se que a maior parte das pesquisas é proveniente de países com infraestrutura tecnológica avançada, especialmente Estados Unidos, Índia, Reino Unido e China, que concentram a maioria dos bancos de dados utilizados para treinamento e validação de algoritmos. A concentração geográfica, embora tenha impulsionado o desenvolvimento técnico, revela uma desigualdade científica que limita a generalização e a equidade diagnóstica dos modelos, sobretudo quando aplicados em populações sub-representadas de contextos latino-americanos e africanos [59], [60].

Do ponto de vista técnico, nota-se uma predominância de estudos voltados à mamografia digital (111 publicações), em detrimento de modalidades mais recentes,

como a tomossíntese, identificada em apenas cinco pesquisas exclusivas. Embora a tomossíntese ofereça vantagens na detecção de lesões sobrepostas, sua aplicação na modelagem de IA ainda é incipiente, o que indica um campo promissor a ser explorado. Da mesma forma, os fabricantes mais recorrentes *Hologic*, *GE* e *Siemens*, demonstram a forte dependência tecnológica das pesquisas em poucos equipamentos, o que reforça o risco de viés de dispositivo e limita a robustez dos algoritmos em ambientes clínicos diversificados. Assim, evidencia-se a necessidade de ampliar a representatividade de fabricantes e promover estudos comparativos que analisem o impacto das variações de hardware e software no desempenho diagnóstico dos modelos.

4.2- Banco de Dados

Um *dataset* robusto precisa conter um número expressivo de imagens mamográficas, idealmente acima de 10.000 exames únicos, distribuídos entre diferentes categorias de densidade mamária, faixas etárias e etnias, para garantir a generalização do modelo e reduzir o viés algorítmico [25]. Além da quantidade, a qualidade das anotações é determinante: cada imagem deve ser rotulada por radiologistas experientes, com marcações precisas de lesões, classificações BI-RADS, lateralidade, tipo de incidência (CC, MLO) e correlação com achados histopatológicos quando disponíveis. Segundo a FDA, bancos de dados voltados a treinamentos de IA médica devem ser “diversificados, balanceados e acompanhados de metadados clínicos completos, contemplando dados demográficos, técnicos e diagnósticos”, assegurando rastreabilidade e auditoria ética [25]. Outro ponto relevante é a conformidade com normas éticas e legais de proteção de dados, como a LGPD no Brasil, é indispensável para assegurar a privacidade das pacientes e a viabilidade do uso clínico da IA [62]. A escolha do banco de dados também deve considerar o volume de dados disponíveis, pois algoritmos de aprendizado profundo requerem grandes quantidades de exemplos para alcançar desempenho superior ao dos especialistas humanos [64].

Na revisão integrativa referente à categoria “banco de dados”, o método aplicado foi a leitura da metodologia dos 135 artigos e identificado os banco de dados utilizados nas pesquisas, nem todos os estudos citaram qual banco foi utilizado e a artigos que tiveram como objetivo desenvolver banco de dados e alguns autores utilizam mais de um banco de dados.

A Figura 31 demonstra o fluxograma desta etapa. Os bancos de dados prontos, foram citados em vinte e dois artigos e o processo de desenvolvimento de bases de dados voltadas à aplicação de IA em mamografia, foram considerados nove artigos com diversos critérios metodológicos. No que tange à caracterização dos bancos de dados existentes, foram analisados aspectos como o país de origem, o volume total de imagens disponíveis, a frequência com que cada base foi citada em publicações científicas, bem como suas principais características estruturais e técnicas.

Figura 31: Fluxograma da identificação dos bancos de dados



Fonte: Da autora (2025)

Quanto ao desenvolvimento de novos bancos de dados, a análise contemplou variáveis como o número de pacientes e de imagens incluídas, a modalidade de imagem empregada (mamografia digital e/ou tomossíntese), o intervalo temporal de coleta dos exames, a quantidade de centros participantes na aquisição dos dados, conforme a Tabela 5. Além dos modelos de IA aplicados e os respectivos objetivos clínicos e computacionais. Esses parâmetros são fundamentais para garantir a representatividade, a qualidade e a aplicabilidade dos dados na construção de sistemas de IA robustos e clinicamente relevantes.

Tabela 5 - Desenvolvimento de Banco de dados

Título	Autor	Pacientes	Imagens	Período coleta	Modalidade	País
ADMANI: Annotated Digital Mammograms and Associated Non-Image Datasets	64	629.863	4.411.263	6 anos	Mamografia	Austrália
Categorized contrast enhanced mammography dataset for diagnostic and artificial intelligence research.	65	326	2.006	2 anos	Mamografia com contraste	Egito
LAMIS-DMDB: A new full field digital mammography database	66	590	2.216	4 anos	Mamografia	Argélia


for breast cancer AI-CAD researches						
Malmo Breast ImaginG database: objectives and development	67	104.791	451.054	16 anos	Mamografia tomossíntese	Suécia
Mammogram mastery: A robust dataset for breast cancer detection and medical education.	68	745	10.430	1 ano	Mamografia	Iraque
medigan: a Python library of pretrained generative models for medical image synthesis	69	não específica	4.360	não específica	Mamografia endoscopia, raios-x e RM	Espanha e Estados Unidos
The EMory BrEast imaging Dataset (EMBED): A Racially Diverse, Granular Dataset of 3.4 Million Screening and Diagnostic Mammographic Images	70	116.902	~3.65 milhões	7 anos	Mamografia tomossíntese	Estados Unidos
Towards precision medicine in breast imaging: A novel open mammography database with tailor-made 3D image retrieval for AI and teaching.	71	100	941	4 anos	Mamografia tomossíntese	Brasil

Fonte: Da autora (2025)

4.2.1 - Banco de dados prontos

Foram identificados 22 bancos de dados previamente estruturados, conforme demonstrado na Figura 32, dos quais 13 são de acesso público, 6 possuem acesso controlado, 3 são privados e 4 correspondem a softwares comerciais. O banco de dados mais amplamente utilizado foi o MIAS (*Mammographic Image Analysis Society*), citado em 15 estudos científicos. Este conjunto contém aproximadamente 1.800 imagens mamográficas, acompanhadas de anotações detalhadas sobre o tipo de tecido mamário (como denso ou adiposo), a presença de anormalidades, o tipo de lesão (incluindo nódulos, calcificações ou distorções arquiteturais), o grau de severidade (benigna ou maligna) e a localização aproximada das alterações observadas. Os países que mais desenvolveram banco de dados para mamografia foram o Reino Unido e os Estados Unidos com a criação de cinco bancos de dados cada um.

Figura 32 - Incidência de citações de banco de dados prontos indicando o país que ele foi desenvolvido



Fonte: Da autora (2025), [57], [58]

O banco de dados *Optiman* destaca-se por apresentar o maior volume de imagens, totalizando cerca de 7 milhões, enquanto o mini-MIAS, com 322 imagens, constitui o menor conjunto identificado. Os principais bancos de dados em mamografia reconhecidos ou utilizados em estudos submetidos à FDA, ou seja, considerados adequados para validação de algoritmos clínicos foram: *Digital Database for Screening Mammography* (DDSM), *Curated Breast Imaging Subset of DDSM* (CBIS-DDSM), *INbreast Dataset*, *OPTIMAM Mammography Image Database* (OMI-DB), *Mammographic Image Analysis Society* (MIAS). Os dispositivos comerciais aprovados pela FDA como o *ProFound AI – iCAD*, *Lunit INSIGHT MMG*, *Transpara* e *Therapixel MammoScreen*, utilizaram bancos clínicos privados com milhões de exames anonimizados, validados segundo protocolos éticos revisados pela FDA e pelo *Institutional Review Board* (IRB), ou seja, Comitê de Revisão Institucional. Esses bancos são confidenciais, mas citam frequentemente DDSM, CBIS-DDSM e OMI-DB como *datasets* (banco de dados) suplementares de treinamento ou calibração externa. [25]

No que se refere à diversidade étnica representada nos bancos de dados,


observa-se uma variação limitada. A maior parte dos conjuntos de dados foi desenvolvida por instituições do Reino Unido e dos Estados Unidos, responsáveis, respectivamente, pela criação de cinco bancos de dados cada. Já países como Austrália, Noruega, Egito, China, Iraque, Portugal e Alemanha contribuíram de forma mais pontual, cada um com apenas um banco de dados voltado à mamografia. É importante destacar que muitos autores utilizaram mais de um banco de dados na sua pesquisa, o que é muito relevante para testar a diversidade de tipos de imagens mamográficas, seus achados radiológicos e algoritmos de cada banco, podendo assim treinar as suas IAs com mais precisão.

A predominância de dados oriundos de populações caucasianas, majoritariamente provenientes de países como Reino Unido e Estados Unidos, compromete a capacidade dos algoritmos de reconhecer padrões morfológicos e densitométricos característicos de outros grupos étnicos, como mulheres afrodescendentes e asiáticas, que apresentam variações anatômicas e fisiológicas relevantes na estrutura mamária [72]. Essa homogeneidade amostral pode gerar vieses algorítmicos, levando à subdetecção de câncer de mama em populações sub-representadas e, conseqüentemente, à ampliação de desigualdades em saúde [73]. Assim, a inclusão intencional de dados multicêntricos e multiétnicos é uma condição essencial para o desenvolvimento de sistemas de IA robustos, éticos e clinicamente aplicáveis em contextos globais [75].

4.2.2 - Desenvolvimento de Banco de Dados

A análise dos nove estudos que desenvolveram bancos de dados para IA aplicada à mamografia evidencia uma expressiva variação tanto na quantidade de imagens quanto na abrangência dos centros de coleta, aspectos fundamentais para a robustez e a capacidade de generalização dos modelos de IA. Na figura 33 é demonstrado a quantidade de imagens e quantidade de centros de coleta de banco desenvolvido.

Figura 33: Número de imagens e centros de coleta por autor.



Fonte: Da autora (2025), [57], [58]

O banco de dados, desenvolvido na Austrália por Frazer *et al* [64], destaca-se como o maior identificado, com 4.411.263 imagens. Contudo, a ausência de informações sobre o número de centros de coleta limita a avaliação da diversidade tecnológica e demográfica do conjunto, comprometendo a análise da heterogeneidade de origem das imagens. Em seguida, o banco criado por Jeong et al [70] nos Estados Unidos reúne cerca de 3,65 milhões de imagens obtidas em quatro centros de coleta, o que favorece uma maior variação de equipamentos e protocolos de aquisição, fator essencial para o desenvolvimento de algoritmos mais generalizáveis e robustos diante de diferentes condições clínicas e técnicas.

Nos estudos de menor escala, observa-se um cenário contrastante. O banco de dados brasileiro elaborado por Monteiro Cordeiro *et al* [71], com 941 imagens provenientes de um único centro, reflete os desafios de infraestrutura e a limitação de diversidade tecnológica, o que pode reduzir a representatividade e aumentar o risco de *overfitting*, (fenômeno em que o modelo aprende padrões específicos do conjunto de treinamento, perdendo capacidade de generalização e precisão em dados externo [22]), quando os modelos são aplicados em outros contextos. Já o estudo conduzido por Khaled *et al.* [65], no Egito, embora tenha incluído apenas 2.006 imagens de um centro de coleta, apresenta um diferencial relevante, o foco em mamografia com

contraste, essa característica confere grande valor científico ao banco, uma vez que os modelos de IA desenvolvidos para mamografias com contraste diferem substancialmente daqueles aplicados a imagens convencionais, tanto na estrutura de dados quanto nas variáveis radiômicas utilizadas. Assim, a existência de um banco específico para mamografia com contraste representa um avanço estratégico na diversificação dos datasets disponíveis e contribui para o aprimoramento de algoritmos voltados a técnicas de diagnóstico mais sensíveis e dinâmicas.

Em síntese, observa-se que quanto maior o número de centros de coleta e a diversidade tecnológica envolvida, maior tende a ser a robustez, a equidade e a capacidade de generalização dos modelos de IA. Por outro lado, bancos uni localizados, embora úteis em estágios iniciais de validação, apresentam limitações para aplicações clínicas amplas, reforçando a necessidade de iniciativas colaborativas e multicêntricas.

4.2.3 - Análise demográfica em relação aos países


Os países responsáveis pelo desenvolvimento das inteligências artificiais identificadas foram Austrália, Egito, Argélia, Suécia, Iraque, Espanha, Estados Unidos e Brasil. Destaca-se que os Estados Unidos participaram em dois estudos distintos: um de forma exclusiva, conduzido por Jeong *et al.*[70], que utilizou aproximadamente 3,65 milhões de imagens de mamografia e tomossíntese, e outro em colaboração, relatado por Osuala *et al.* [69], cujo banco de dados compreendeu 4.360 imagens provenientes de mamografias, endoscopias, radiografias e ressonâncias magnéticas. No contexto brasileiro, identificou-se apenas um conjunto de dados, elaborado por Monteiro et al. [71], com 941 imagens, o que ainda representa um volume pouco expressivo para a construção e validação de modelos de IA.

Ao se considerar tanto os bancos de dados já existentes quanto aqueles desenvolvidos especificamente para as pesquisas, observa-se a incorporação de uma diversidade razoável de origens étnicas. Contudo, verifica-se uma sub-representação significativa de mulheres afrodescendentes e asiáticas, o que constitui uma limitação relevante para a validação e a generalização dos modelos de IA aplicados à mamografia, uma vez que a ausência de diversidade demográfica compromete o desempenho equitativo dos algoritmos e a confiabilidade dos resultados obtidos [75]; [76].

4.2.4 - Tempo de coleta de imagens

O tempo médio da coleta de dados teve bastante variação, conforme observado na Figura 34, não teve uma tendência específica. Os períodos mais longos foram o estudo de Dahlblom *et al.* [67] por 16 anos e a pesquisa de Cossío *et al.* [77] por 13 anos. O período mais curto no estudo de 1 ano pelo autor Aqdar *et al.* [68].

Figura 34: Período de coleta de imagens



Fonte: Da autora (2025), [57], [58]

Quanto maior o período de coleta, maior a probabilidade de incorporar variações tecnológicas, demográficas e clínicas que refletem a heterogeneidade real dos exames mamográficos. Isso contribui para modelos mais generalizáveis e menos suscetíveis ao *overfitting*, ampliando sua aplicabilidade em diferentes contextos populacionais e equipamentos de imagem. Por outro lado, bases de dados construídas em períodos muito longos podem introduzir viés temporal, decorrente da evolução dos dispositivos de mamografia (por exemplo, da tecnologia analógica para a digital e, mais recentemente, para a tomossíntese), o que impacta diretamente a consistência das características radiômicas e da acurácia preditiva dos algoritmos [59]; [60]. Assim, o equilíbrio entre extensão temporal e uniformidade tecnológica constitui um fator crítico para assegurar a validade externa e a confiabilidade clínica dos modelos de IA em mamografia.

4.2.5 - Modelos de IAs na construção de banco de dados

Nos estudos analisados, diversos modelos de IA foram empregados para o desenvolvimento, aprimoramento e validação de bancos de dados de mamografia. Esses modelos apresentam abordagens distintas, desde redes neurais convolucionais (CNNs) até arquiteturas generativas adversariais (GANs) e métodos de explicabilidade, este método, são técnicas que tornam os modelos de IA mais transparentes, permitindo compreender como e por que eles chegam a determinadas decisões ou previsões. Deste modo, reflete o avanço e a diversidade de técnicas aplicadas à área da detecção precoce do câncer de mama. A Tabela 6 sintetiza os modelos identificados nos artigos durante a revisão integrativa.

Tabela 6 - Modelos de IAs utilizados na construção de banco de imagens

Autor	Modelo de IA
65	EfficientNetB0 , GradCam, GANs
66	EfficientNetB7 , Segmentação
69	DCGAN, CycleGAN, pix2pix, C-DCGAN, WGAN-GP: M
70	EfficientDet-b0, VGG11 com batch normalization , Character-level BERT
77	Lunit INSIGHT MMG v1.1.7.2, Therapixel MammoScreen v2.1.0, Vara v2.1

Fonte: Da autora (2025)

A família *EfficientNet*, proposta por Tan e Le [78], representa uma das arquiteturas de CNN mais eficientes para análise de imagens médicas, pois equilibra profundidade, largura e resolução da rede por meio de um método de escalonamento composto. Essa abordagem permite alto desempenho com menor custo computacional, sendo amplamente utilizada em tarefas de classificação de imagens mamográficas e detecção de anomalias. O modelo *EfficientNetB0*, de menor porte, é ideal para bancos com número limitado de imagens; enquanto o *EfficientNetB7* é uma versão mais profunda, com maior capacidade de generalização [78].

O método Grad-CAM (*Gradient-weighted Class Activation Mapping*) é uma técnica de explicabilidade que permite visualizar quais regiões da imagem influenciaram a decisão de uma rede neural. No contexto da mamografia, o Grad-CAM é empregado para gerar mapas de calor que evidenciam áreas suspeitas,

facilitando a validação clínica dos modelos e aumentando a transparência da IA [79].

As GANs, propostas por Goodfellow *et al.* [80], são redes compostas por dois modelos em competição, um gerador e um discriminador, capazes de criar imagens sintéticas realistas. Na mamografia, são utilizadas para aumentar o tamanho dos bancos de dados, corrigir desequilíbrios de classes e gerar variações anatômicas simuladas, essenciais para reduzir o overfitting e ampliar a robustez dos algoritmos.

As variações como DCGAN e WGAN-GP aprimoram a estabilidade do treinamento; CycleGAN e Pix2Pix são usadas para tradução de imagem para imagem, como simular diferentes modalidades (ex.: mamografia com e sem contraste), e C-DCGAN permite controle condicional sobre as imagens geradas. [81]; [82]; [83]; [84].

O modelo *EfficientDet-B0* é uma variação orientada à detecção de objetos derivada da *EfficientNet*, incorporando uma rede de fusão ponderada de características (BiFPN), o que otimiza a identificação de lesões e microcalcificações em mamografias [78]. Já a VGG11, proposta por Simonyia [86] e Zisserman [85], é uma rede clássica que, com a adição de “batch normalization” (normalização por lote), aumenta a estabilidade do treinamento e reduz o risco de sobreajuste, sendo útil em bancos com variação limitada de imagens.

O modelo Character-level BERT, derivado da arquitetura “*Bidirectional Encoder Representations from Transformers*”, ou seja, “Representações Bidirecionais de Codificadores baseadas em Transformadores” é aplicado para o processamento de textos associados aos metadados dos bancos (como relatórios, descrições clínicas e anotações). Sua função é analisar e padronizar informações não estruturadas, o que contribui para a integridade semântica dos bancos de dados e para o aprendizado multimodal entre imagem e texto [86].

Além das arquiteturas abertas, destacam-se modelos comerciais validados clinicamente:

- Lunit INSIGHT MMG v1.1.7.2, baseado em CNNs profundas, aprovado pela FDA para detecção de achados suspeitos e priorização de exames [87];
- Therapixel MammoScreen v2.1.0, que atua como segunda leitura automatizada, reduzindo o tempo de interpretação e aumentando a sensibilidade do radiologista [88];
- Vara v2.1, voltada à triagem automatizada, combinando aprendizado supervisionado e explicabilidade para priorização de casos suspeitos [89].

A diversidade de modelos identificados demonstra um ecossistema de IA em rápida evolução. Contudo, observa-se que muitos bancos de dados ainda são desenvolvidos sem integração explícita de modelos de aprendizado profundo, como verificado nos trabalhos de Frazer *et al.* [64], Dahlblom *et al.* [67], Aqdar *et al.* [68] e Monteiro Cordeiro *et al.* [71], o que revela uma lacuna metodológica na interoperabilidade entre bancos de dados e algoritmos. Essa ausência reforça a necessidade de padrões técnicos abertos e *datasets* multi-institucionais, garantindo maior diversidade e generalização dos modelos de IA aplicados à mamografia [60].

Em síntese, a análise dos bancos de dados consolidados e dos recentemente desenvolvidos para pesquisas evidencia uma diversidade étnica apenas moderada. Entretanto, observa-se uma marcante sub-representação de mulheres afrodescendentes e asiáticas, o que configura uma limitação significativa para a validação e a generalização dos modelos de IA aplicados à mamografia. Entre os principais bancos de dados amplamente reconhecidos e utilizados em estudos submetidos à FDA, destacam-se o *DDSM*, *CBIS-DDSM*, o *INbreast*, o *OPTIMAM* e *MIAS*. Esses conjuntos mostraram-se uma tendência na construção de modelos de IA em mamografia e tomossíntese.

Entre os bancos de dados desenvolvidos, dois estudos se destacaram pelo volume de imagens e pela extensão temporal da coleta. O banco australiano proposto por Frazer *et al.* [64] foi o maior identificado, com 4.411.263 imagens. Contudo, a ausência de informações sobre o número de centros de coleta limita a avaliação da diversidade tecnológica e demográfica, dificultando a análise da heterogeneidade de origem das imagens. Já o banco elaborado por Jeong *et al.* [70], nos Estados Unidos, reúne aproximadamente 3,65 milhões de imagens obtidas em quatro centros de coleta, o que favorece uma maior variabilidade de equipamentos e protocolos de aquisição, elemento fundamental para o desenvolvimento de algoritmos mais generalizáveis e robustos em diferentes contextos clínicos e técnicos.

Em contrapartida, o estudo conduzido por Khaled *et al.* [65], no Egito, embora tenha incluído apenas 2.006 imagens provenientes de um único centro, apresenta um diferencial notável, o uso de mamografias com contraste. Essa especificidade confere elevado valor científico ao banco, uma vez que os modelos de IA voltados à mamografia contrastada diferem significativamente daqueles baseados em imagens convencionais, tanto na estrutura dos dados quanto nas variáveis radiômicas

exploradas. Sugere-se a inclusão desta técnica para novos bancos de dados para aumentar a eficiência dos modelos de IA, como também a inclusão de bancos específicos com mamografias com implante mamário, pois a imagem também difere da mamografia sem implante, podendo atrapalhar a leitura do modelo de IA, não foram mencionados de forma clara a inclusão destas imagens.

De modo geral, quanto maior o período e a amplitude da coleta de dados, maior tende a ser a incorporação de variações tecnológicas, demográficas e clínicas, refletindo a complexidade real dos exames mamográficos. Essa heterogeneidade contribui para a criação de modelos mais generalizáveis e menos suscetíveis ao *overfitting*. Assim, conforme discutido por McDermott *et al.* [60], a criação de bancos de dados amplos, diversificados e transparentes é essencial para o desenvolvimento de modelos de IA robustos e reproduzíveis.

A variedade de modelos de IA identificados nos estudos analisados demonstra um ecossistema científico em rápida evolução. Contudo, para consolidar avanços consistentes, recomenda-se que os próximos trabalhos descrevam detalhadamente as arquiteturas utilizadas, os critérios metodológicos empregados e as métricas de desempenho adotadas, assegurando transparência, comparabilidade e rigor na avaliação da efetividade dos modelos desenvolvidos.

4.3. Comparação entre IA e Radiologista

A incorporação da IA na radiologia mamária tem revolucionado a forma como os exames são interpretados, proporcionando um avanço significativo na detecção precoce do câncer de mama. O desenvolvimento de algoritmos baseados em DL e CNN tem permitido a análise automatizada de imagens mamográficas com níveis de acurácia comparáveis, em alguns casos, aos de especialistas experientes [90]. Esses sistemas são capazes de identificar padrões sutis e características morfológicas imperceptíveis ao olho humano, potencializando a capacidade diagnóstica e reduzindo as taxas de erro associadas à fadiga ou à variabilidade interobservador. Nos últimos anos, a aplicação da IA à mamografia tem se consolidado como uma das vertentes mais promissoras no rastreamento e diagnóstico precoce do câncer de mama. Diversos estudos clínicos multicêntricos têm buscado comparar a acurácia dos algoritmos de IA com a de radiologistas experientes, demonstrando resultados que variam conforme o tipo de modelo, o volume de dados de treinamento e o perfil

das populações analisadas. O trabalho de McKinney *et al.* [91], publicado na revista *Nature*, é considerado um marco por demonstrar que uma rede neural profunda treinada com mais de 76.000 exames mamográficos alcançou desempenho comparável ao de radiologistas na detecção de cânceres invasivos, reduzindo falsos positivos e falsos negativos. Esse tipo de evidência sugere o potencial da IA como ferramenta de segunda leitura, ampliando a sensibilidade diagnóstica sem substituir o julgamento clínico humano. Compreender comparativamente o desempenho diagnóstico entre IA e radiologistas é fundamental para definir papéis complementares, orientar políticas de implementação segura e fomentar práticas radiológicas baseadas em evidências, capazes de equilibrar automação, precisão e responsabilidade clínica.

O método aplicado nesta pesquisa foi a leitura do resumo e métodos dos 135 artigos para identificar quais artigos compararam a IA com o Radiologista através de métricas. Foram identificados 19 artigos que relataram métricas na comparação do uso da IA e sem a IA com o Radiologista. As principais métricas relatadas são descritas na Tabela 7 abaixo.

Tabela 7: Métricas de avaliação do modelo de IA

Métrica	Característica
AUC	representa a capacidade discriminatória do teste
Acurácia	indica o percentual de acertos
Sensibilidade	mede a detecção correta de casos positivos
Especificidade	avalia a identificação correta de casos negativos,
VPP e VPN	refletem a confiabilidade das predições positivas e negativas, respectivamente

Fonte: [92], [93]

Na Tabela 8, é apresentado os dados do nome do autor, o número de médicos radiologistas participantes da pesquisa, o país de realização do estudo e os modelos de IA empregados na pesquisa.

Tabela 8 :Relação entre quantidade de radiologistas, país e modelos de IA

Autor	Qdade. Radiologistas	País	Modelos de IA
94	2	Alemanha	Espectros de Wiener normalizados (nWS),
95	2	Egito	MVCM — Multiview Contrast Mammography Model.
96	12	China	Redes neurais convolucionais (CNNs)
97	2	Romênia	AlexNet
98	15	Estados Unidos, Coreia do Sul	CNN, ResNet-34 , Lunit INSIGHT DBT
99	3	Coreia do Sul	YOLO (You Only Look Once)
101	não especifica	Dinamarca	Lunit INSIGHT MMG versão 1.1.7.1
102	não especifica	Noruega	Lunit INSIGHT MMG versão 1.1.7.2.
103	5	China	RefineNet, CBAM (Convolutional Block Attention Module), XGBoost Classifier

104	2	Suiça	Deep Convolutional Neural Network (dCNN)
105	22	Dinamarca	Transpara
106	não especifica	Estados Unidos, Suécia	Therapixel model, Faster R-CNN, CEM (Challenge Ensemble Method)
107	3	China	ResNeXt-50
108	não especifica	Estados Unidos	Challenge Ensemble Method (CEM)
109	10	Coreia do Sul	Lunit INSIGHT MMG
110	101	Estados Unidos	não especifica
111	não especifica	Egito	Lunit INSIGHT MMG,
112	8	Alemanha	ProFound AI
113	5	Alemanha	Transpara

Fonte: Da autora (2025)

Observa-se uma concentração de pesquisas em países com maior infraestrutura tecnológica, como Estados Unidos, Coreia do Sul, China e países europeus, utilizando majoritariamente modelos baseados em redes neurais convolucionais (CNNs) e soluções comerciais já consolidadas, como Lunit INSIGHT MMG/DBT, Transpara, ProFound AI e modelos ensemble (como o CEM). Esse cenário indica que a validação dos modelos de IA em mamografia tem sido conduzida

em contextos específicos, com forte presença de países desenvolvidos e participação limitada de radiologistas na maioria dos estudos, o que pode restringir a generalização dos resultados para outros contextos clínicos. A participação da quantidade de radiologistas é discutida no item 4.3.1.

Na Tabela 9, são descritas as métricas reportadas. Nos casos em que o autor não especificou alguma métrica, foi adotada a sigla N/A (não se aplica). Os valores das métricas indicadas correspondem aos maiores resultados mencionados nos respectivos artigos. Quando o estudo avaliou múltiplos modelos de inteligência artificial, foi incluído apenas aquele que demonstrou o melhor desempenho. Importante destacar que nem todos os artigos citaram todas as métricas, o que limita a análise de eficiência da comparação entre IA e Radiologista.

Tabela 9: Métricas comparação IA com Radiologista.

Autor	AUC IA	Acurácia IA	Especificidade IA	Sensibilidade IA	VPP IA	VPN IA	AUC Radiologista	Acurácia Radiologista	Sensibilidade Radiologista	Especificidade Radiologista	VPP Radiologista	VPN Radiologista
94	80,80%	84,00%	76,00%	78,00%	N/A	N/A	N/A	82,00%	78,00%	75,00%	N/A	N/A
95	93,60%	90,90%	96,30%	75,00%	87,10%	92,00%	N/A	91,70%	88,90%	92,60%	80,00%	96,20%
96	85,50%	N/A	N/A	90,80%	N/A	N/A	N/A	N/A	94,36%	N/A	87,76%	99,09%
97	99,10%	99,28%	N/A	N/A	N/A	N/A	N/A	78,03%	N/A	N/A	N/A	N/A
98	93,00%	N/A	83,00%	88,57%	N/A	N/A	N/A	0.90	85,44%	77,34%	N/A	N/A
99	91,00%	87,20%	85,10%	89,50%	84,30%	90,20%	89,00%	85,60%	88,10%	83,20%	82,70%	88,90%
101	N/A	N/A	97,85%	75,36%	22,34%	99,79%	N/A	N/A	74,03%	97,84%	21,98%	99,78%
102	95,60%	N/A	90,4%	94,50%	N/A	N/A	N/A	N/A	90,30%	95,4%	N/A	N/A
103	93,20%	85,70%	70,00%	90,30%	67,70%	N/A	N/A	84,20%	66,70%	90,20%	64,60%	N/A
104	N/A	89,80%	100,00%	84,00%	N/A	N/A	N/A	N/A	88,00%	86,20%	N/A	N/A
105	N/A	N/A	97,90%	74,60%	22,00%	99,80%	N/A	N/A	73,90%	97,90%	22,00%	99,80%
106	90,30%	N/A	81,20%	85,90%	N/A	N/A	94,20%	N/A	85,90%	98,50%	N/A	N/A
107	79,00%	74,1%	61,1%	80,6%	80,6%	61,1%	89,00%	88,9%	88,9%	72,7%	94,1%	80,0%
108	93,00%	N/A	92,50%	81,30%	N/A	N/A	93,00%	N/A	82,60%	93,00%	N/A	N/A

109	91,00%		N/A	N/A	N/A	N/A	81,00%	N/A	88.6%	66.4%	N/A	N/A
110	84,00%	N/A	41,00%	91,00%	N/A	N/A	81,40%	N/A	N/A	N/A	N/A	N/A
111	N/A	90.30%	73.91%	93.69%	94.55%	70.83%	N/A	82.84%	100,00%	N/A	82.84%	N/A
112	89,00%	N/A	80,20%	81,70%	N/A	N/A	N/A	N/A	78,60%	91,60%	N/A	N/A
113	N/A	N/A	38,00%	91,10%	16,50%	N/A	N/A	N/A	96,70%	11,10%	12,80%	N/A

Fonte: Da autora (2025)

Nesta análise foi identificado que o estudo de Chen, *et al.*[99] e Wan *et al.* [107] foram os únicos que avaliaram todas as métricas. As métricas da IA no estudo de Chen *et al.* [99] foram um pouco maiores que as dos Radiologistas. Na pesquisa de Wan *et al.* [107], as melhores métricas foram do Radiologista com auxílio da IA.

No estudo de Badawy *et al.* [111], foi utilizado o modelo comercial Lunit INSIGHT MMG, a pesquisa demonstrou que IA foi mais precisa do que os radiologistas na detecção de lesões malignas em mamografias digitais BIRADS 4 e 5. A IA obteve uma acurácia de 90,30%, superando os 82,84% alcançados pelos radiologistas. Embora os radiologistas apresentassem uma sensibilidade de 100%, a IA se destacou com um valor preditivo positivo significativamente maior (94,55% contra 82,84% dos radiologistas). No entanto, a sensibilidade do radiologista foi superior. A análise histopatológica foi utilizada como padrão de referência, e os resultados sugerem que a IA pode ser um aliado valioso para os radiologistas, proporcionando maior precisão na triagem de lesões malignas, mas sem substituir completamente o julgamento clínico humano

Na pesquisa de Kerschke *et al.* [113], a aplicação da IA modelo Transpara, reduziu significativamente a proporção de mulheres com falsos positivos, de 89,9% para 62,0%, enquanto aumentou a taxa de exames sem falsos positivos de 11,1% para 38,0%. Em termos de sensibilidade, houve uma pequena queda de 96,7% para 91,1%, indicando que algumas lesões malignas deixaram de ser identificadas pelo sistema. A análise específica de massas mostrou que a IA apresentou sensibilidade comparável à dos radiologistas, com uma redução substancial de falsos positivos. O valor preditivo positivo aumentou de 12,8% para 16,5%, sugerindo que a IA pode otimizar a eficiência do rastreamento.

A pesquisa de Squires *et al.* [114], não avaliou nenhuma métrica, porém investigou o modo de diferentes rotulações de densidade mamográfica, fornecidas por radiologistas, influenciam o desempenho de modelos de DL e se a variabilidade

interleitores afeta tanto as representações internas quanto a qualidade das predições. Para essa análise, foram empregadas métricas como a *Spearman Rank Correlation*, a fim de aferir a concordância entre os rankings das predições do modelo e os escores atribuídos pelos leitores, o RMSE para mensurar o erro médio quadrático entre valores previstos e escores reais, e o Odds Ratio em subconjunto de dados para examinar a associação entre densidade prevista e risco de câncer de mama. Em termos de arquitetura, utilizou-se uma DenseNet pré-treinada no ImageNet como extrator de características, acoplada a regressão linear para predição de densidade, e uma ResNet-18, também pré-treinada, em dois arranjos end-to-end: um modelo single-predictor, com saída única de densidade, e um modelo multi-predictor, com 13 saídas correspondentes a leitores específicos, concebido para lidar com a variabilidade das etiquetas. Os resultados indicaram que a variabilidade dos rótulos afeta de modo significativo a relação entre as representações extraídas e a predição final de densidade, embora o impacto sobre a representação apreendida em si seja mínima. Em consequência, modelos treinados em bases distintas podem não ser diretamente comparáveis devido a diferenças de escala dos rótulos, mas suas representações internas mostram potencial de transferência para outras aplicações clínicas. Assim, no desenvolvimento de modelos de DL voltados à predição de densidade mamográfica, torna-se imprescindível considerar a variabilidade dos rótulos para assegurar a confiabilidade das predições em diferentes contextos.


A pesquisa de Ghosh [115], também não avaliou nenhuma métrica, mas o estudo investigou a eficácia de um fluxo de trabalho baseado na colaboração entre IA e radiologistas, utilizando conjuntos de dados abertos do BI-RADS. O objetivo foi verificar se a inclusão da classificação BI-RADS atribuída por radiologistas, em conjunto com parâmetros de imagem, melhoraria a acurácia na predição de resultados histológicos de lesões mamárias. Dois conjuntos de dados distintos foram usados com três algoritmos de aprendizado de máquina (rede neural artificial, vetor de máquina de suporte e rede bayesiana). Os modelos que integraram a opinião do radiologista apresentaram desempenho significativamente superior. Os resultados sugerem que o trabalho conjunto entre IA e radiologistas pode aprimorar a tomada de decisões clínicas.

O estudo de Tao *et al.* [116] avaliou métricas somente da IA e teve por objetivo criar conjuntos de testes personalizados com o objetivo de melhorar o desempenho de grupos específicos de leitores de mamografias. Foram analisados 60 casos

mamográficos de alta densidade, interpretados por 36 radiologistas divididos em dois grupos distintos. Modelos de aprendizado de máquina foram treinados para prever erros diagnósticos, utilizando características radiômicas extraídas de regiões de interesse das imagens. Os resultados demonstraram que a abordagem proposta foi capaz de prever erros falso-positivos e falso-negativos, mas apresentou limitações na detecção de erros de localização. Esses achados sugerem que a adaptação de materiais educativos com base nas dificuldades específicas de cada grupo de leitores pode contribuir para aprimorar a interpretação de mamografias.

4.3.1. Participação dos Radiologistas

O estudo de Sechopoulos, Ioannis, Ritse [110], teve a maior participação de radiologistas, totalizando 101 participantes, seguido de Tao *et al.* [116] com 36 radiologistas e Elhakim *et al.* [101] com 22 radiologistas, conforme demonstrado na Figura 35.



Fonte: Da autora (2025), [57], [58]

A participação dos radiologistas nos estudos que comparam o desempenho diagnóstico entre IA e especialistas humanos é um fator determinante para a robustez metodológica e a validade dos resultados obtidos. Quanto menor o número de

radiologistas envolvidos, maior a probabilidade de viés individual e menor a representatividade das métricas avaliadas, comprometendo a generalização dos achados para a prática clínica. Conforme salientam McKinney *et al.* [24], a diversidade de avaliadores humanos permite estabelecer um parâmetro de referência mais confiável para a análise comparativa entre IA e radiologista, reduzindo o impacto de diferenças subjetivas de interpretação. Os estudos multicêntricos com ampla participação de radiologistas tendem a refletir melhor a variabilidade real do ambiente clínico, assegurando maior validade externa aos modelos de IA [60]. Assim, a limitação na quantidade de radiologistas avaliadores deve ser considerada um importante fator metodológico que influencia diretamente a acurácia das métricas comparativas e a aplicabilidade dos algoritmos em cenários clínicos diversos.

Resumidamente a análise comparativa dos estudos evidencia que a integração entre a IA e a interpretação humana representa a principal tendência na evolução do diagnóstico mamográfico. Embora modelos autônomos, como o Lunit INSIGHT MMG, demonstrem níveis de acurácia superiores aos dos radiologistas em determinados contextos clínicos, o consenso entre as pesquisas de Chen *et al.* [99], Wan *et al.* [107] e Ghosh [115] confirmam que os melhores resultados são obtidos por meio de abordagens colaborativas, nas quais a IA atua como suporte à decisão e não como substituta do profissional. Tais achados apontam para uma mudança de paradigma, em que a IA assume papel de “segunda leitura” ou de sistema de triagem inteligente, potencializando a sensibilidade e a especificidade diagnóstica, além de reduzir o número de falsos positivos, como demonstrado no modelo Transpara por Kerschke *et al.*, [113]. Essa convergência entre eficiência algorítmica e julgamento clínico humano reforça que o futuro da mamografia digital depende da interoperabilidade entre tecnologia e expertise médica, priorizando a acurácia e a equidade no rastreamento do câncer de mama.

Apesar dos avanços observados, persistem lacunas estruturais e metodológicas que limitam a plena integração da IA à prática clínica. A ausência de padronização na avaliação das métricas, a variabilidade dos rótulos utilizados para o treinamento dos modelos, como evidenciado por Squires *et al.* [114] e a escassez de bancos de dados multi-institucionais e multiétnicos ainda comprometem a generalização e a validação externa dos algoritmos. Estudos como o de Tao *et al.* [116], apontam também a necessidade de desenvolver modelos adaptativos voltados ao aprimoramento do desempenho de radiologistas em diferentes níveis de

experiência, sugerindo um movimento emergente em direção à IA educacional e personalizada. Assim, as próximas direções de pesquisa devem concentrar-se na criação de *datasets* diversificados, com no uso de métricas harmonizadas e na implementação de frameworks híbridos entendidos como estruturas de colaboração em que algoritmos de inteligência artificial e especialistas humanos compartilham e articulam, de forma complementar, etapas de triagem, interpretação e tomada de decisão clínica, favorecendo uma leitura mamográfica mais precisa, inclusiva e contextualizada.

Outro ponto é que a participação reduzida de radiologistas avaliadores configura-se como uma limitação metodológica relevante, uma vez que impacta diretamente a precisão das métricas comparativas e restringe a aplicabilidade dos algoritmos em contextos clínicos mais amplos e heterogêneos.

4.4. Tendências de pesquisa no campo da IA em mamografia

A aplicação da IA na mamografia tem se expandido em múltiplas direções, refletindo o esforço global para aprimorar a detecção precoce e o diagnóstico do câncer de mama. A diversidade de abordagens evidencia o amadurecimento científico do campo, com estudos voltados para diferentes finalidades, como a classificação automática de lesões, a detecção de câncer em exames de rastreamento, o desenvolvimento de modelos específicos para microcalcificações e massas mamárias, e até algoritmos de segmentação que servem como base para novas arquiteturas de aprendizado profundo [110]; [60]. Essa multiplicidade de cenários demonstra que a IA não se limita a reproduzir a leitura humana, mas amplia o potencial diagnóstico ao explorar características invisíveis ao olho clínico, como padrões sutis de textura, contraste e densidade mamária.


A validação desses algoritmos depende de uma análise rigorosa de suas métricas de desempenho, que expressam não apenas a capacidade do modelo em reconhecer padrões, mas também sua confiabilidade na prática clínica. Métricas como acurácia, sensibilidade, especificidade, valor preditivo positivo (VPP), valor preditivo negativo (VPN) e a área sob a curva ROC (AUC) são essenciais para comparar modelos e compreender seus limites em diferentes cenários diagnósticos [107]; [99]. A interpretação crítica dessas métricas é fundamental, pois um modelo com alta sensibilidade, mas baixa especificidade, pode aumentar a taxa de

reconvocação, enquanto o oposto pode levar à perda de casos malignos, ambos resultados indesejáveis em programas de rastreamento populacional.

Nesse contexto, torna-se relevante mapear as tendências recentes de pesquisa e compreender como os estudos têm abordado cada uma dessas dimensões da IA em mamografia. A classificação temática dos trabalhos permite identificar lacunas entre áreas de maior e menor investimento científico, revelando, por exemplo, o predomínio de estudos voltados à detecção e classificação em detrimento de abordagens mais complexas, como a segmentação de distorções arquiteturais ou a modelagem do risco longitudinal. Ao reunir evidências sobre o foco dos estudos, o tamanho e a diversidade dos conjuntos de dados e o desempenho dos modelos, esta pesquisa contribui para delinear caminhos futuros para o desenvolvimento de IAs mais robustas, generalizáveis e eticamente aplicáveis à prática radiológica [1]

Para identificar o cenário atual, esta pesquisa aplicou a leitura dos resumos, métodos, resultados e conclusão dos 135 artigos e separados os artigos em tabelas pelo foco do estudo e identificado o país de desenvolvimento, quantidade de imagens que foram incluídos no estudo, quantidade de centros de coleta, os modelos de IA utilizados e as métricas (AUC, Acurácia, Especificidade, Sensibilidade, VPP e VPN).

Os objetivos encontrados estão descritos na Figura 36 com a quantidade de artigos foram: IAs para Classificação do Câncer de mama; Detecção Câncer de Mama; Desenvolvimento IA para Microcalcificações, Desenvolvimento IA para massas mamárias, Comparação entre IAs, IAs para prever o risco do câncer de mama, IAs na avaliação de densidades mamárias, Detecção da distorção arquitetural, Segmentação para desenvolver IAs em mamografia e Outras categorias que tiveram objetivos diversificados.

Figura 36: Objetivos da IA em Mamografia

Fonte: da Autora (2025)

Os resultados foram separados por objetivos e serão descritos abaixo, a análise foi realizada através das métricas apresentadas.

4.4.1. IAs para Classificação do Câncer de mama

Na Tabela 10, estão descritos todos os artigos que desenvolveram IAs com o objetivo de classificar os achados radiológicos em mamografias ou tomossíntese, como nódulos, microcalcificações ou distorção arquitetural, em benignas ou malignas, auxiliando o Radiologista no diagnóstico. Nesta categoria foram encontrados 12 artigos, estes utilizaram diferentes bancos de dados prontos ou utilizaram centros de coleta de imagem, percebe-se uma grande variação na quantidade de imagens para o desenvolvimento de cada IA, sendo o menor conjunto com 312 imagens no estudo de Zhang *et al* [117] e o maior conjunto de imagens de

55.890 imagens na pesquisa do Alshayegi; Al-Buloushi [118].

Tabela 10: Classificação Câncer de mama

Aut or	País	Qdade image ns	Centros de coleta ou Banco de dados	Modelo de IA	AUC	Acur ácia	Espec ificida de	Sens ibilid ade	VPN	VPP
119	Egito	1.219	MIAS DDSM CBIS- DDSM	ResNet50 e VGG-16	98,46 %	97,98 %	Não especif ica	97,63 %	N/A	N/A
120	Esta dos Unid os	22689	4	Du-Rad Du- Res Net	81%	45%	N/A	N/A	N/A	N/A
121	Israel e Esta dos Unid os	9.234	20	XGBoost (Extreme Gradient Boosting) e Fusão multimodal	88%	N/A	N/A	98,70 %	N/A	N/A
118	Kuwait	55.890	DDSM CBIS- DDSM	CNN, Transfer Learning com InceptionResNetV2, Transfer Learning com Xception	N/A	99,13 %	N/A	N/A	N/A	N/A
122	Paquistão	2620	CBIS- DDSM	cVGG (compact VGG), VGG16, ResNet50, DenseNet121, InceptionResNetV1	N/A	91,50 %	N/A	N/A	N/A	N/A
123	Espanha, Egito, Reino Unido	985	DBTex Challenge	AlexNet, VGG19, ResNet50WideResNet101, SqueezeNet, EfficientNet	80%	80,43 %	73,91 %	91%	N/A	N/A
124	Arábia Saudita	12.208	DDSM, DBTex Challenge Dataset	AlexNet, CNN personalizada, ABER	N/A	99,40 %	99,40 %	99,30 %	99,20 %	99,20 %
125	Esta dos Unid os	1.709	1	VGG16, PyTorch, GPU Nvidia TESLA V100	N/A	N/A	N/A	N/A	N/A	N/A
126	Arábia	410	INbreast	AlexNet VGG16	N/A	98,50 %	98,99 %	98,06 %	98,98 %	N/A

	Saudita, Coreia do Sul, Egito			GooleNet						
127	India	11.262	DDSM, MIAS, INbreast	CNN	N/A	99,38%	N/A	99%	99%	N/A
128	Egito	318	MIAS	Random Forest	N/A	97%	N/A	N/A	N/A	N/A
117	Itália	312	1	Decision Tree, Artificial Neural Network, SVM, Linear Discriminant Analysis, KNN	0.90	87%	87%	86%	88%	86%


Fonte: Da autora (2025)

Os modelos de IAs utilizados também variaram bastante, nem todos os estudos relataram as métricas de AUC, Acurácia, Especificidade, Sensibilidade, VPP e VPN da IA, entre os estudos que citam, é possível identificar que o estudo de Salama *et al.* [119] teve o maior AUC, com 98,46% que utilizou o modelo de IA ResNet50 com a combinação de redes convolucionais pré-treinada e SVM, provou ser altamente eficaz para a classificação de câncer de mama em mamografias. O uso de aprendizado por transferência e aumento de dados contribuiu para superar a limitação de amostras rotuladas e melhorar a generalização dos modelos. A técnica proposta oferece uma solução promissora e precisa, eliminando a necessidade de engenharia manual de características e processos de pré ou pós-processamento, sendo adequada para aplicações clínicas em tempo real. O estudo não menciona se as imagens estão na projeção CC, MLO e com implante mamário e se estão em DICOM.

O estudo com maior acurácia, especificidade, sensibilidade, VPP e VPN dos artigos que citaram as métricas foi o de Alhussan *et al.* [124] com 99,40% de acurácia e especificidade, sensibilidade de 99,30% e VPN e VPP com 99,20%. Este estudo apresenta uma abordagem automatizada para a classificação de casos de câncer de mama utilizando aprendizado profundo aliado a uma técnica de otimização de última geração, a Advanced Al-Biruni Earth Radius (ABER). A metodologia propõe a extração de características a partir de imagens de mamografia com a rede pré-treinada AlexNet, combinada à otimização da estrutura e parâmetros de um modelo de rede neural convolucional (CNN). O sistema foi avaliado em dois conjuntos de

dados públicos, atingindo acurácia média de 97,95%. Testes estatísticos, como ANOVA e Wilcoxon, reforçaram a superioridade da proposta frente a métodos atuais, destacando seu potencial para aprimorar a acurácia e robustez na detecção precoce do câncer de mama (Figura 37). O estudo não menciona se foram incluídas as imagens na projeção CC, MLO e com implante mamário, também não menciona se as imagens estão em DICOM.

Figura 37: O processo de extração de características do conjunto de dados de imagens de câncer de mama.



Fonte: [124]

4.4.2. Detecção Câncer de Mama

Foram identificados vinte e um artigos com o objetivo central em desenvolver IAs para detectar o câncer de mama, estes modelos de IAs chamam atenção dos Radiologistas para áreas suspeitas e que merecem atenção do profissional para identificar possíveis lesões malignas.

Na Tabela 11 estão descritos todos os estudos encontrados com esse objetivo. O estudo que apresentou a maior quantidade de imagens foi o de Chen *et al.* [129], que utilizou os conjuntos de dados ADMANI e CBIS-DDSM. O estudo que apresentou a menor quantidade de imagens foi o estudo de Sakthivel *et al.* [130], Mamum *et al.* [131] e Karthiga *et al.* [132] que utilizaram o banco de dados mini-MIAS com 322 imagens.

Tabela 11: Detecção câncer de mama

A u t o r	País	Qt de im ag en s	Banc os de dados	Modelos de IA	A UC	Ac ur á ci a	Se nsi bil id ade	Es pe cif ici dade	VP P	VP N
130	Índia	322	mini-MIAS	AlexNet Deep Convolutional Neural Network, Gradient-Based Optimizer, Support Vector Machine	N/A	98%	95%	N/A	N/A	N/A
131	Bangladesh	322	mini-MIAS	MobileNetv5_S, Small, VGG19, InceptionV3	94,07%	93,62%	N/A	N/A	N/A	N/A
129	Austrália	4084068	ADMANI e CBIS-DDSM BRAIDset	MVAICVLC (Multi-View Cancer Classification Learning)	N/A	N/A	N/A	N/A	N/A	N/A
133	Paquistão, Sudão, Coreia do Sul	3002	não específica	Random Forest (RF), Decision Tree (DT), K-Nearest Neighbors Regression (LR), Support Vector Classifier (SVC), Linear SVC	96,49%	N/A	N/A	N/A	N/A	N/A
134	Arábia Saudita	1802	1	Xception, Gradient Boosting	95%	87%	N/A	N/A	N/A	N/A
135	Índia	570579	TCAI, CBIS-DDSM, VICTRE-CMMD, CDD-CESM, Breast Diagnostics	ResNet50, InceptionV3, AlexNet, VGG16, VGG19	97,99%	80,08%	98,43%	99,5%	15,14%	N/A
136	Estados Unidos, China, Irã, Iraque	2620	CBIS-DDSM, INbreast, Profound AI,	ZTFNet, ELM, SWM-CHA	96,89%	94,09%	96,87%	96,73%	N/A	N/A

			DMIS, Transpara rsa							
137	Paquistão	2797	CBIS- DDSM, MIAS, Profound AI (CAdE) Transpara rsa	DeFBCD (Diverse Features based Breast Cancer Detection), CNN, ELM, SVM	86,0 0%	82%	N/A	N/A	N/A	N/A
138	Kuwait	não espe cífica	DDSM	CIN (dedicada), com LBP	99,1 0%	N/A	N/A	N/A	N/A	N/A
139	Vietnã	731	1	Xception, VGG16, SVM (Linear, K- Nearest Neighbors (KNN), Random Forest Machine (SVM)), Artificial Network (ANN), Gradient Boosting Machine (GBM)	85,0 0%	84,5 0%	76,1 0%	84,5 0%	N/A	N/A
140	Índia	1710 1	CBIS- DDSM, Mamma ry Mammo gram Dataset	Enchanted Harmony Search Algorithm, Light Gradient Boosting Machine, NN (GBM)	N/A	96,3 3%	96,8 7%	N/A	N/A	N/A
141	Índia	1034 2	DDSM, MIAS	NasNetLight, ODN (Deep Quantum Neural Network), S- Inception	N/A	96,3 3%	92,7 8%	N/A	N/A	N/A
150	Israel	1190 8	DDSM, INbreast	EfficientNetV2	87%	N/A	N/A	N/A	N/A	N/A
132	Índia	322	mini- MIAS	Hybrid Deep Neural Network	92,8 4%	84,6 2%	86,8 0%	N/A	N/A	N/A
151	Egito	1000	MIAS, DDSM	Q-classifier, SVM- RFE com CBR	N/A	98,1 6%	97,8 0%	98,6 3%	N/A	N/A
152	Irã	1290	Motamed Cancer Institute (ACECR)	RF, Gradient Boosting Trees, Multi-Layer Perceptron, Algoritmo Genético	59%	74%	86%	82%	31%	N/A
153	Finlândia	1582	1	End2End, DMV- CNN, GMIC, GLAM	68,8 0%	N/A	N/A	N/A	N/A	N/A
154	Turquia	1196 8	3	ResNet-50	N/A	80%	N/A	69%	N/A	N/A
155	Suécia	429	4	Transpara v1.5.0	N/A	N/A	N/A	N/A	N/A	N/A

156	Grécia	410	INBreast	Rank-R Fully-connected Neural Network (Rank-R FNN)	N/A	90%	N/A	N/A	N/A	N/A
157	Noruega	6616 95	8	Lunit Insight MMG, versão 1.1.7.2	97,0 0%	N/A	99,3 0%	99,3 0%	N/A	N/A

Fonte: Da autora (2025)

Foram identificados diversos modelos de IAs e 2 softwares comerciais (Lunit Insight MMG e Transpara) que avaliaram o desempenho do algoritmo. O modelo comercial Transpara, avaliado por Lång *et al.* [155], não avaliou métricas como AUC, acurácia, sensibilidade, especificidade, VPP e VPN, porém o estudo demonstrou que o uso da IA em mamografias de rastreamento pode potencialmente reduzir em até 19,3% a taxa de câncer de intervalo, aqueles que surgem entre exames e geralmente têm pior prognóstico. A IA conseguiu identificar corretamente sinais mínimos ou lesões que haviam sido interpretadas erroneamente por radiologistas em exames anteriores, com destaque para casos mais agressivos: 23% dos cânceres com desfecho grave (estágio IV ou óbito) foram corretamente localizados pela IA. Esses achados indicam que a IA pode ser uma ferramenta eficaz para aumentar a sensibilidade do rastreamento mamográfico sem necessidade de métodos adicionais, contribuindo para diagnósticos mais precoces e possivelmente melhores desfechos clínicos.

No modelo comercial Lunit Insight MMG, avaliado por Larsen *et al.* [157], demonstrou um desempenho elevado na detecção de cânceres de mama, com uma área sob a curva de característica operativa (AUC) de 0,93 para a detecção de cânceres combinados (screen-detected e intervalares). Quando o risco mais alto era utilizado como critério para definir exames positivos, a IA identificou 92% dos cânceres detectados no rastreamento e 44,6% dos cânceres intervalares. Com um limiar de 50% de risco, a IA foi capaz de identificar 99,3% dos cânceres detectados no rastreamento e 85,2% dos cânceres intervalares. A IA mostrou potencial para reduzir a carga de trabalho dos radiologistas, identificando corretamente os exames de baixo risco e permitindo triagem de mamografias sem a necessidade de intervenção radiológica para esses casos.


O estudo que apresentou maior acurácia foi a pesquisa de Manali, *et al.* [138], este estudo propõe um sistema CAD baseado em inteligência artificial para detecção

precoce de câncer de mama a partir de mamografias. O sistema utiliza três canais paralelos de classificação: um CNN dedicado, uma combinação de ResNet50 com SVM, e um SVM com extração de características via LBP. As saídas dos três modelos são fundidas por regras de decisão (soma, produto e votação majoritária) para aumentar a precisão do diagnóstico. Com um conjunto de dados balanceado da DDSM, a abordagem alcançou 99,1% de acurácia usando a regra do produto. A proposta demonstra grande potencial para auxiliar radiologistas na detecção eficiente de tumores mamários, reduzindo erros diagnósticos e promovendo intervenções precoces. O estudo não especificou a quantidade de imagens utilizadas e se estão em DICOM, é mencionado que foram utilizadas imagens em CC e MLO mas não foi relatado se foram incluídas imagens com implantes mamários.

A pesquisa com maior especificidade foi de Kumar *et al.* [140], o artigo apresenta o desenvolvimento de um modelo híbrido denominado Enhanced Harmony Search Algorithm-based Light Gradient-Boosting Machine-Enabled Neural Network (EHA-LNN), ou seja, Algoritmo Aprimorado de Busca por Harmonia baseado em Rede Neural habilitada por Máquina de Gradiente Leve (Light Gradient Boosting Machine – LGBM), demonstrado na Figura 38, para detecção de câncer de mama em imagens de mamografia. A proposta surge como resposta às limitações de métodos anteriores, que sofriam com sobreajuste, baixa interpretabilidade, elevada taxa de falsos positivos e complexidade computacional. O modelo integra técnicas de pré-processamento, segmentação e extração de características com o uso conjunto de LightGBM e redes neurais, otimizados pelo algoritmo Enhanced Harmony Search (EHA), visando maior acurácia, velocidade de convergência e melhor generalização. O estudo utilizou 17.101 imagens do banco de dados CBIS-DDSM e Mammogram Mastery Dataset, o modelo EHA-LNN alcançou desempenho superior em relação a métodos tradicionais. Atingiu uma acurácia máxima de 98,63%, sensibilidade de 98,99% e especificidade de 98,27%, superando modelos como Decision Tree, LightGBM isolado, redes neurais simples e outras versões híbridas. O estudo apresentou menor tempo computacional e estabilidade em diferentes validações (Training Percentage- TP de 90% de treinamento e K-Fold validação cruzada em 9 partições para avaliar a robustez do modelo), confirmando sua eficácia para apoiar radiologistas na interpretação de mamografias. O artigo não menciona quais incidências mamográficas foram utilizadas, se foram incluídas imagens com implante

mamário e se as imagens estão em formato DICOM.

Figura 38: Análise experimental do modelo EHA-LNN para detecção de câncer de mama



Fonte: Adaptado [140]

O estudo com maior sensibilidade foi o de Karthiga et al., (2024) com o valor de 100% e maior VPN com 80%. O estudo propõe uma abordagem híbrida de inteligência artificial para a detecção automatizada de câncer de mama em imagens de mamografia, utilizando técnicas de aprendizado profundo e extração de características via transformada wavelet de Haar (método matemático que reescreve um sinal em termos de médias e diferenças em vários níveis, permitindo enxergar tanto o “todo” quanto os detalhes finos do sinal). A metodologia integra pré-processamento eficiente, extração de regiões de interesse (ROI) e uso de características estatísticas e texturais para alimentar modelos de aprendizado de máquina e uma rede neural convolucional modificada. Os experimentos foram conduzidos com o banco de dados MIAS, contendo 322 imagens mamográficas rotuladas. O modelo híbrido de CNN, utilizando características extraídas via wavelet, alcançou uma acurácia de 84,62% e uma área sob a curva ROC (AUC) de 0,92, superando significativamente os métodos de aprendizado de máquina isolados, como

LDA (81,4%), SVM e KNN. A CNN demonstrou maior capacidade de generalização e robustez na classificação binária (câncer/não câncer), especialmente quando combinada com técnicas de otimização como o otimizador RMSProp. Os resultados validam a eficácia da abordagem híbrida para diagnósticos assistidos por computador em mamografias, porém vale ressaltar que o conjunto de dados com 322 imagens é considerado baixo para a validação e não foram citadas informações sobre as projeções CC e MLO, se foram incluídas imagens com implante mamário e se as imagens estão em DICOM.


A pesquisa de Pati *et al.*[135], apresentou o maior VPP com 99,51%, este estudo propõe um sistema automatizado de diagnóstico de câncer de mama baseado em imagens de mamografia, utilizando modelos de aprendizado profundo com transferência de aprendizado (DTL), integrados a uma arquitetura de computação em névoa (*Fog Computing*) e Internet das Coisas (IoT). A pesquisa utilizou imagens de repositórios públicos com 570.579 imagens para treinar modelos com diferentes redes neurais convolucionais pré-treinadas, combinadas com uma máquina de vetores de suporte (SVM). A abordagem proposta não apenas melhora a precisão da detecção de câncer de mama, mas também promove diagnósticos remotos em tempo real, respeitando a privacidade dos dados e otimizando o uso da rede e da energia. As imagens originalmente estavam em DICOM, Durante o pré-processamento, essas imagens foram convertidas para formato PNG, preservando os valores de pixel originais para treinamento dos modelos. Não foram mencionadas a projeção em CC ou MLO e não menciona se foram incluídas imagens com implante mamário.

4.4.3 - Desenvolvimento IA para Microcalcificações

Foram identificados cinco artigos que dedicaram sua pesquisa em na detecção ou classificação de microcalcificações em mamografias. Na Tabela 12 podemos identificar que o estudo de Leong *et al.*[158] da Malásia teve o maior número de imagens incluídas, porém não especifica a quantidade de centros de coleta. O artigo apresenta o desenvolvimento de uma arquitetura inédita de rede neural convolucional profunda (D-CNN) com aprendizado por transferência adaptativo para discriminar microcalcificações em mamografias, visando o diagnóstico rápido e precoce do câncer de mama. Utilizando imagens de regiões de interesse (ROI) do banco CBIS-DDSM, o estudo aplicou pré-processamentos para remoção de artefatos e ruídos, padronização e realce por filtro de mediana adaptativa, treinando e comparando

modelos como ResNet50, ResNet34, VGG16 e AlexNet, conforme visualizado na Figura 39, onde (A) Comparação da aplicação da remoção de artefatos com a implementação do Método de Segmentação de Otsu e do Método MorphologicalEx em uma amostra de imagem mamográfica completa. (B) Comparação antes e depois da aplicação do filtro de mediana adaptativo.

Figura 39 : Pré-processamentos para remoção de artefatos e ruídos



Fonte: [158]

Os resultados demonstraram que, após a aplicação das etapas de pré-processamento e treinamento com diferentes arquiteturas de redes neurais convolucionais profundas, o modelo ResNet50 obteve o melhor desempenho na classificação de microcalcificações em mamografias, alcançando acurácia de 97,58%, especificidade e VPP de 100% e uma sensibilidade de 99,88%. A combinação de um conjunto de dados de alta resolução, pré-processamento eficaz e ajuste refinado de hiperparâmetros potencializa o desempenho de modelos de DL na detecção precoce de câncer de mama. O estudo utilizou imagens nas incidências CC e MLO, mas não foi mencionado a inclusão de imagens com implante mamário e se as imagens estão em formato DICOM.

Tabela 12- IAs dedicadas a Microcalcificações


Au to r	Paí s	Q t d e i m a g e n s	Qtd de centr os de imag ens	Modelo de IA	AU C	Ac urá cia	Esp eci fica da de	Sen sibi lida de	VP P	VP N
158	Malás ia	611 1	não específi ca	ResNet50, ResNet34, VGG16, AlexNet	N/A	97.58 %	100%	99.88 %	100%	N/A
159	Japão	136	1	FSRCNN (Fast Super- Resolution Convolutio nal Neural Network)	N/A	N/A	N/A	N/A	N/A	N/A
160	China	824	1	MobileNet V2	91,00 %	91,90 %	85,30 %	90,60 %	90,00 %	87,20 %
161	Itália	198 6	1	AlexNet, ResNet18, ResNet34	98,00 %	98%	89%	98%	96%	94%
162	Itália	252	1	RF, SVM e SVM com função de base radial, Regressão Logística	59,00 %	58%	61%	56%	N/A	N/A

Fonte: da Autora (2025)

O estudo com maior AUC descrito é o de Pesapane *et al.* [161] com uma taxa de 98%. O estudo investiga o potencial de modelos de inteligência artificial baseados em DL para detectar e classificar microcalcificações em mamografias, que são sinais precoces de câncer de mama conforme a Figura 40. Considerando a sobrecarga dos radiologistas e a alta demanda por exames, a pesquisa buscou desenvolver uma ferramenta capaz de auxiliar na triagem, localização e caracterização das lesões, oferecendo maior precisão diagnóstica e suporte à prática clínica. Foram utilizadas redes neurais convolucionais (AlexNet, ResNet18 e ResNet34) em um conjunto de mamografias anotadas por especialistas, com o objetivo de verificar sua eficácia em

diferenciar microcalcificações benignas e maligna. Foram incluídas imagens na projeção CC e MLO em formato DICOM, mas não menciona imagens com implante mamário.

Figura 40- Exemplo de anotações de microcalcificações suspeitas em projeção CC.



Fonte: [161]

4.4.3. Desenvolvimento IA para massas mamárias

Na Tabela 13 são apresentados os oito artigos que se dedicaram ao uso da IA focados em massas mamárias.

Tabela 13: IAs dedicadas as massas mamárias

A u t o r	Pa ís	Qt d de im ag en s	Qtd de cent ros de ban co de ima gen s	Model o de IA	Objetivo	AUC	Ac ur á ci a	Es pe cif ici da de	S e n si bi li da de	V P P	V P N
163	Chin a	512	2	Deepwise Multi- modal Research Platform V1.0, PyRadiom ics, PyTorch, ResNet- 34	Classificaçã o massas mamárias	90,80 %	83.3 %	80.7 %	86.2 %	N/ A	N/A
164	Chin a	596	4	ResNet50 , CBAM, Balanced Sampler, PyRadiom ics	Classificaçã o massas mamárias	N/A	87.4 %	N/A	N/A	N/ A	N/A
165	Port ugal	410	INbrea st	EfficientN et-B0, Support Vector Machine	Classificaçã o massas mamárias	N/A	94.4 8%	99.2 1%	94.7 9%	94. 79 %	N/A
166	Chin a	não espe cifica	não especif ica	UNet aprimora do	Segmentaç ão de massas tumoriais	N/A	N/A	N/A	N/A	N/ A	N/A
167	Paqu istão	2002	INbrea st, CBIS- DDSM	Skipping Dilated Semantic CNN	Segmentaç ão de massas tumoriais	98,95 %	N/A	N/A	N/A	N/ A	N/A
168	Estad os Unid os	891	CBIS- DDSM	Bag-of- Visual- Words (BoVW), LASSO Logistic Regressio n, CNN – DenseNet -121,	Classificaçã o massas mamárias	86,00 %	N/A	N/A	N/A	N/ A	N/A


				LDA- RBST, NN- HDF							
169	Índia	1940	MIAS, DDSM, ID (Internally collected dataset)	CNN, AlexNet, VGG16, kNN	Classificação de massas mamárias	96,00 %	96.4 7%	N/A	N/A	N/A	N/A
170	Colômbia	1446	CBIS- DDSM, INbreast	UNet (base), VGG19, Inception ResNetV2 ,Efficient Net, MobileNetV2, ResNet, ResNeXt, MultiRes UNet, LinkNet- VGG19, DenseNet, SE- ResNet, SeResNeXt, ResNet50v2, DenseNet121, EfficientNetB7, Xception	Comparar 12 IAs na detecção de massas mamárias	99,96 %	99.9 9%	95.2 1%	N/A	N/A	N/A

Fonte: Da autora (2025)

O estudo que utilizou o maior número de imagens foi o de Zahoor, Shoaib, Lali [167], o estudo propõe um novo *framework* para segmentação de massas mamárias, demonstrado na Figura 41, combinando uma rede semântica dilatada com conexões de atalho (*Skip Dilated Semantic Network – SDSN*) e algoritmos de ML para refinar a segmentação. A abordagem visa superar desafios comuns na detecção de bordas de massas irregulares e em ambientes com baixo contraste. O método utiliza uma arquitetura de rede neural convolucional aprimorada, complementada por classificadores como SVM, KNN e Random Forest, otimizando o desempenho na

etapa de pós-processamento. A SDSN alcançou métricas de desempenho superiores em termos de Dice Similarity Coefficient (DSC), precisão e sensibilidade, o DSC é usado para medir o grau de sobreposição entre duas amostras ou conjuntos. A aplicação dos algoritmos de ML como etapa de refino contribuiu para a melhoria dos contornos segmentados, principalmente na eliminação de ruídos e áreas irrelevantes. Entre os classificadores testados, o *Random Forest* apresentou os melhores resultados, complementando a segmentação inicial de forma eficiente. O estudo utilizou imagens CC e MLO em formato DICOM, porém não é mencionado a inclusão de pacientes com implante mamário.

Figura 41: Resultados do conjunto de dados CBIS-DDSM com segmentação semântica dilatada ignorada e sem fator de dilatação.



Fonte: [167]

O estudo com maior AUC com uma taxa de 96% foi na pesquisa de Gnanasekaran *et al.*[169]. O estudo propõe um modelo de CNN para a classificação

automática de massas mamárias em imagens de mamografia, categorizando-as como benignas, malignas ou normais. Utilizando três bases de dados distintas (MIAS, DDSM e um conjunto interno), o modelo foi desenvolvido com quatro blocos de camadas convolucionais, pooling e dropout, seguido por camadas totalmente conectadas. Os resultados obtidos com o modelo proposto superaram os de arquiteturas pré-treinadas (AlexNet e VGG16) e também de algoritmos de aprendizado de máquina, como o kNN, alcançando até 98,32% de acurácia em conjunto de dados unificados, demonstrando sua eficiência e aplicabilidade na detecção assistida por computador para o câncer de mama. O estudo incluiu imagens na projeção CC e MLO, porém não menciona se estão em formato DICOM e se foram incluídas imagens com implante mamário.

O estudo com maior acurácia que foi de 99,96% e especificidade com 99,99% e maior sensibilidade com 95,21% foi o de Anaya-Isaza *et al.* [170]. Este estudo propõe uma análise comparativa de doze arquiteturas de redes neurais convolucionais profundas (CNNs) aplicadas à segmentação e classificação de lesões mamárias em mamografias digitais. As redes foram avaliadas sob cinco diferentes funções de perda para segmentação e com base em duas tarefas de classificação: tipo de lesão e grau de suspeita de malignidade (BI-RADS). Utilizando bases de dados públicas (CBIS-DDSM, MIAS e INbreast), os modelos foram submetidos a estratégias robustas de validação e pré-processamento, incluindo aumento de dados. Os resultados demonstraram que a arquitetura EfficientNet, combinada com a função de perda de entropia cruzada binária (medida da diferença entre duas distribuições de probabilidade, aplicada aqui a cada pixel da imagem para classificar entre duas classes: fundo e região de interesse), superou métodos do estado da arte na tarefa de segmentação, enquanto as redes VGG19 e ResNet50V2 obtiveram o melhor desempenho nas tarefas de classificação. O estudo não menciona a projeção em CC ou MLO, se estão em formato DICOM e se foram incluídas imagens com implante mamário.

4.4.4- Comparação entre IAs

Os 9 estudos descritos na Tabela 13, avaliaram a eficiência de diferentes modelos de IAs, com objetivos distintos descritos na coluna “objetivos”.

Tabela 13: Comparação entre IAs

A u t o r	Pa ís	Qda de ima gen s	Ce nt ro s de co let a ou Ba nc o de da do s	Modelo de IA	Objetivo	A U C	A c u r á c i a	E s p e c i f i c i d a d e	Se ns i bi li d a d e	V P P	VPN
171	Esta dos Unid os	108.23 0	33	framework DeepNeuro e backend Keras/TensorFlo w.	Classificação automatizada da densidade mamária	N/ A	N/ A	88 %	83%	N/A	N/A
172	Áustr ia	não especif ica	1	Transpara 1.7.0, ProFound AI 3.0	Avaliar o desempenho de dois sistemas de IA (Transpara e ProFound AI) na detecção de malignidades	86 %	N/ A	60. 9%	100%	N/A	99,97%
173	Esta dos Unid os	~700	1	Regressão logística com regularização (L2), SVM – Support Vector Machine	Avaliar o viés de desempenho causado pela forma como os dados são divididos entre conjuntos de treinamento e teste	N/ A	N/ A	N/ A	N/A	N/A	N/A
174	Chin a	118	1	LASSO, RF, SVM, GBM, GLM, K-Nearest Neighbors (KNN), Neural Network (NNET)	Prever a resposta à quimioterapia neoadjuvante em pacientes com câncer de mama.	87, 00 %	N/ A	N/ A	72.4 %	N/A	N/A
175	Colô mbia	402	Mini- MIAS , BCD R	Histogram of Oriented Gradients (HOG), Adaptive Boosting	Comparar o desempenho dos descritores HOG e Haar na detecção câncer de mama	N/ A	N/ A	85 %	92.5 %	N/A	N/A

170	Colômbia	1.446	CBIS - DDS M, MIAS, INbreast	UNet (base), VGG19, InceptionResNet V2, EfficientNet, MobileNetv2, ResNet, ResNeXt, MultiResUNet, LinkNet-VGG19, DenseNet, SEResNet, SeResNeXt, ResNet50V2, DenseNet121, InceptionV3, EfficientNetB7, Xception	Comparar 12 IAs na detecção de massas mamárias	N/A	99,96 %	99,99 %	95,21 %	N/A	N/A
178	Índia	322	MIAS	SVM, Naive Bayes, Bayes Net, Multilayer Perceptron, Simple Logistic, Random Forest, Random Tree, J48 (árvore de decisão), Logistic Model Tree, REPTree	Avaliar o efeito de diferentes técnicas de binarização de imagens na identificação de câncer de mama	N/A	99,68 %	N/A	N/A	N/A	N/A
179	Índia	1.820	DDSM	Transfer Learning, AlexNet, GoogLeNet,	Detecção e classificação de massas mamárias	N/A	96,7%.	91 %	98%	N/A	N/A
180	Estados Unidos	764	5	Genius AI Detection e CAdE	Comparar IAs na detecção de câncer de mama	87,00 %	N/A	54,3%	96,2 %	N/A	N/A

Fonte: Da autora (2025)

O estudo com maior acurácia e especificidade foi descrito na seção IAs dedicadas a massas mamárias por Anaya-Isaza *et al.* [170].


O estudo conduzido por Resch *et al.* [172] teve a maior sensibilidade com 100% e VPN de 99,97%, teve como objetivo comparar o desempenho diagnóstico de dois sistemas comerciais de IA baseados em deep learning (Transpara 1.7.0 e ProFound AI 3.0) aplicados à mamografia com tomossíntese digital (DBT), utilizando como referência a dupla leitura humana padrão em pacientes assintomáticas. A análise retrospectiva envolveu 419 mulheres, das quais 58 apresentaram câncer de mama confirmado por biópsia. Os resultados revelaram que, embora ambos os sistemas de IA tenham demonstrado alta sensibilidade na detecção de malignidades (sem falhar na identificação de nenhum caso classificado como de baixo risco), o

desempenho geral foi inferior ao da leitura humana dupla (AUC: 0,98), sendo o ProFound AI superior ao Transpara (AUC: 0,93 vs. 0,86; $p = 0,004$), especialmente em mamas não densas. O estudo destaca o potencial da IA como ferramenta complementar promissora, mas reforça a necessidade de estudos prospectivos multicêntricos para avaliar sua aplicabilidade clínica real e superar limitações como a “caixa-preta” algorítmica, vies de seleção e ausência de validação ampla.

O estudo de Bahl *et al* [180] comparou o desempenho de um algoritmo tradicional de detecção assistida por computador (CAdE) aplicado a mamografias sintéticas 2D com um algoritmo moderno de IA baseado em DL aplicado a tomossíntese mamária digital- DBT usando o mesmo conjunto de 764 exames (106 com câncer confirmado por biópsia). Os resultados mostraram que a IA 3D superou significativamente o CAdE 2D em todas as métricas principais: maior área sob a curva ROC (AUC de 0,873 vs. 0,693), maior sensibilidade específica por lesão (94,3% vs. 72,6%) e maior especificidade (54,3% vs. 16,7%), além de apresentar menos falsos-positivos. Essa superioridade se manteve tanto em mamas densas quanto não densas, indicando que a aplicação da IA à DBT pode melhorar substancialmente a precisão diagnóstica e reduzir marcações falsas, potencialmente impactando de forma positiva a prática clínica e os desfechos para as pacientes.

Um exemplo está na Figura 42, a mamografia é de uma mulher de 65 anos com exame normal e tecido mamário heterogeneamente denso. Os resultados demonstrados na imagem (a) com a IA não apresenta marcas falso-positivas, enquanto na mamografia (b) com o CAdE exibe múltiplas marcas falso-positivas.

Figura 42: Exemplo de imagem com marcações de IA e CAdE em uma paciente sem câncer



Fonte: [180]

4.4.5. IAs para prever o risco do câncer de mama

Foram identificados oito artigos com o objetivo de prever o câncer de mama, os estudos estão descritos na Tabela 14, percebe-se que em quatro artigos foi utilizado o modelo de IA Mirai.

Tabela 14: IAs desenvolvidas para prever o câncer de mama

A u t o r	País	Qtd e ima gens	Banc os de dado s	Mo del os de IA	Objetiv o	A UC	A c u r á c i a	Se nsi bil id ad e	Es pe cif ici da de	VP P	V P N
181	Paquistão, Polônia , Arábia Saudita , Reino Unido, Índia	5427	CBIS-DDSM	2- Residual Blocks CNN, 3- Residual Blocks CNN	IA para prever a resposta de pacientes com câncer de mama à quimioterapia neoadjuvante	71%	N/A	90%	46%	N/A	N/A

182	Inglaterra	não específica	PROCA S	MAI-risk	Prever o risco de câncer de mama a curto prazo	74,70%	N/A	N/A	N/A	N/A	N/A
183	Estados Unidos	318	2	Long Short-Term Memory (LSTM)	Prever o risco de câncer de mama	65%	N/A	N/A	N/A	N/A	N/A
184	Reino Unido	5075	OPTIM AM	ML-only, DL-only, ML-DL (híbrido)	Prever o câncer de mama	76,00%	N/A	66,40%	70,30%	68,00%	N/A
185	Reino Unido	29920	OPTIM AM	Mirai	Prever o câncer de mama	72%	N/A	N/A	N/A	N/A	N/A
186	Estados Unidos	6435	1	Mirai	Prever o câncer de mama	71,00%	N/A	80,50%	36,30%	N/A	N/A
187	Estados Unidos	200000	não específica	Mirai	Prever o câncer de mama	75,00%	N/A	N/A	N/A	N/A	N/A
188	México	3110	1	Mirai	Prever o câncer de mama	63,00%	N/A	N/A	N/A	N/A	N/A

Fonte: Da autora (2025)


O estudo de Damiani *et al.* [185] utilizou a maior quantidade de imagens com aproximadamente 29.920. Este estudo avaliou um modelo de IA para prever o risco de câncer de mama nos anos seguintes a um exame de mamografia sem diagnóstico positivo. Utilizando um estudo retrospectivo caso-controle com dados do Programa Nacional de Triagem de Mama do Reino Unido, o modelo foi testado em pacientes diagnosticadas com câncer de mama em diferentes momentos da triagem. O modelo de IA apresentou uma AUC geral de 0,68, indicando uma capacidade preditiva superior à da densidade mamográfica isolada. Não houve diferença estatisticamente significativa no desempenho do modelo entre câncer de intervalo e câncer detectado na triagem. O modelo foi mais eficaz na previsão de cânceres em estágio avançado

(AUC = 0,72) e câncer invasivo receptor de estrogênio positivo (AUC = 0,69). A análise longitudinal mostrou que o risco projetado pelo modelo aumentou progressivamente nos anos que antecederam o diagnóstico. Foram incluídas imagens em CC e MLO, formato DICOM, mas não menciona se foram incluídas imagens com implante mamário.

Mendes *et al.* [184] teve o maior AUC, com 76%, sensibilidade 70,30% e o maior VPP com 68%. Um modelo de predição de risco de três anos, com uma abordagem de caso-controle pareada por idade, foi desenvolvido com base na análise de mamografias saudáveis “anteriores”. Duas classes foram definidas “risco” e “controle”, com base na avaliação feita no exame mais recente: se o caso foi diagnosticado com câncer, a mamografia anterior foi atribuída à classe “risco”; caso contrário, a mamografia anterior foi alocada à classe “normal”. No total foram encontrados 3720 controles disponíveis e 1471 casos de risco. Cada mamografia usada neste estudo foi feita 3 anos antes da avaliação usada para definição de classe. A predição de risco foi direcionada por meio de três metodologias: aprendizado de máquina tradicional, aprendizado profundo e uma combinação de ambas. As AUCs obtidas no conjunto de teste foram 0,68 para o aprendizado de máquina tradicional e 0,76 para os outros dois. Não foram encontradas diferenças estatisticamente significativas entre os métodos. Os autores sugerem que o uso de métodos de aprendizado profundo baseados em imagens é promissor no campo da previsão de risco de câncer de mama, sendo necessária validação adicional para confirmar sua aplicabilidade clínica. Foram incluídas imagens em CC e MLO, formato DICOM, mas não menciona se foram incluídas imagens com implante mamário.

No esquema metodológico de Mendes *et al* [184] para prever o câncer de mama (Figura 43), seguiu as seguintes etapas: a imagem(a) Abordagem somente DL, as imagens são alimentadas diretamente no modelo CNN, responsável por aprender as características que melhor diferenciam entre as duas classes; etapa (b) Abordagem somente ML, o *PyRadiomics* é utilizado para extrair características das imagens de entrada, que, se significativas, são fornecidas a diferentes modelos clássicos de ML para classificação; e (c) Abordagem ML-DL combinada, as características significativas da abordagem somente ML são concatenadas com as características da abordagem somente DL, que correspondem à saída da última camada da CNN antes da camada de classificação. A matriz resultante é então utilizada pelos classificadores de ML.

Figura 43: Metodologia para prever o risco de câncer de mama



Fonte: [184]

A maior especificidade foi citada no estudo de Skarping *et al.* [181] com 90%. Este estudo investigou o uso de IA para prever a resposta de pacientes com câncer de mama à quimioterapia neoadjuvante por meio da análise de mamografias digitais. Utilizando uma abordagem baseada em DL, um modelo foi treinado para identificar padrões associados à resposta patológica completa (pCR). Pesquisas futuras são necessárias para aprimorar a precisão do modelo e explorar sua aplicabilidade em diferentes contextos clínicos.

4.4.6 - IAs na avaliação de densidades mamárias

Foram identificados oito artigos focados na categoria densidade mamária, descritos na Tabela 15.

Tabela 15 - IAs na identificação de densidade mamária

A u t o r	País	Qtd e ima gen s	Ban cos de dad os	Modelos de IA	Objeti vo	A U C	Ac ur ác ia	Se ns ibi lid ade	Es pe cif ici dade	V P P	V P N
-----------------------	------	-----------------------------	-------------------------------	------------------	--------------	-------------	----------------------	-------------------------------	--------------------------------	-------------	-------------

189	Índia, Emirados Árabes Unidos, Arábia Saudita, Marrocos	800	não específica	Multichannel DenseNet121	Classificação da densidade mamográfica	96,25%	90,06%	N/A	86,60%	N/A	N/A
190	Texas	3713	1	U-Net modificada	Viabilizar análises retroativas de densidade e textura mamária	N/A	N/A	N/A	N/A	N/A	N/A
191	Estados Unidos	15661	2	CNNs, Arquitetura U-Net, Algoritmo de Superpixels + Aprendizado Radiômico	Quantificar a densidade mamária	61,20%	N/A	N/A	N/A	N/A	N/A
192	Itália	1184	2	TRACE4B Density, ResNet50	Classificar a densidade mamária	N/A	89,30%	N/A	N/A	N/A	N/A
193	Estados Unidos	58894	3	CNN	Classificação da densidade mamária	N/A	N/A	N/A	N/A	N/A	N/A
194	Itália	não específica	1	SVM (Support Vector Machine), Árvore de Decisão (part), LDA (Linear Discriminant Analysis),	Classificação densidade mamária	N/A	93,55%	92,31%	94,44%	N/A	N/A

				Random Forest (RF)							
195	Reino Unido	31468	PROCAS, ALDRAM	ResNet-18	Densidade de mamária a partir de mamografias de baixa dose	N/A	N/A	N/A	N/A	N/A	N/A
196	Reino Unido	16172	PROCAS e ALDRAM	ResNet-18	Densidade de mamária em mamografia de baixa dose	N/A	N/A	N/A	N/A	N/A	N/A


Fonte: Da autora (2025)

A pesquisa conduzida por Pawar *et al.*[189], envolveu diversos países (Índia, Emirados Árabes Unidos, Arábia Saudita, Marrocos) e apresentou a maior AUC (96,25%), o estudo propõe uma arquitetura multicanal DenseNet para a classificação da densidade mamográfica, um importante biomarcador na detecção do câncer de mama. Utilizando imagens de mamografia digital em quatro vistas diferentes, a abordagem emprega aprendizado profundo para melhorar a acurácia da classificação das categorias de densidade do sistema BI-RADS. A metodologia inclui pré-processamento das imagens para remoção de artefatos e realce de contraste, além da aplicação de um modelo de transferência de aprendizado para extração de características. A capacidade do modelo de lidar com imagens de diferentes ângulos simultaneamente melhora a robustez da classificação e pode contribuir para aprimorar os programas de rastreamento do câncer de mama. Embora o estudo tenha sido conduzido com um conjunto de dados limitado (800 imagens), os achados sugerem que a abordagem pode ser expandida e aprimorada com maior diversidade de imagens e técnicas de aumento de dados. Futuros desenvolvimentos podem focar na adaptação do modelo para diferentes bancos de dados e na validação clínica para integração em sistemas de apoio ao diagnóstico.

Na Figura 44 é demonstrado a classificação BIRADS para densidade mamária: (A) classe gordurosa A (B) gordura com algum tecido fibro glandular - classe B (C)

classe densa heterogênea C (D) extremamente denso-classe D.

Figura 44: Arquitetura multicanal proposta para classificação da densidade mamária



Fonte: [189]

O estudo de Angelone *et al.* [194], obteve a maior acurácia 93,55%, especificidade 92,31% e a maior sensibilidade 94,44%. O estudo propõe um fluxo de trabalho baseado em aprendizado de máquina para a predição do risco de câncer de mama a partir de mamografias digitais, com foco na classificação automática da densidade mamária, um fator de risco relevante para a doença. Foram extraídas características texturais das imagens e utilizadas para treinar diferentes algoritmos de aprendizado de máquina e redes neurais, conforme as diretrizes do BI-RADS. Os resultados indicam que a abordagem binária apresentou alta acurácia, enquanto a classificação multiclasse obteve um desempenho inferior. A proposta pode contribuir para reduzir a carga de trabalho dos radiologistas e melhorar a triagem de mamografias. Foram incluídas imagens em CC e MLO em DICOM, porém não especifica a inclusão de imagens com implante mamário.

Importante destacar que o autor Squires, realizou dois estudos em 2024 para avaliar mamografia de baixa dose na avaliação de densidade, nos 2 estudos foram incluídas imagens em CC e MLO em formato DICOM, mas não especificaram a utilização de imagem com implante. No estudo Squires *et al.* [195] avaliou o impacto da resolução da imagem e da abordagem de treinamento na predição da densidade mamográfica a partir de mamografias de baixa dose utilizando DL. Foram testados três modelos baseados em ResNet-18 em cinco diferentes resoluções, usando dados do PROCAS (mamografias de dose padrão e simuladas de baixa dose) e do ALDRAM (imagens reais de dose padrão e baixa dose). Os resultados mostraram uma forte

correlação entre as predições nas imagens de baixa e alta dose (Spearman de até 0,956), demonstrando que modelos de DL podem fornecer estimativas confiáveis da densidade mamográfica com baixa dose de radiação. Conclui-se que o uso de mamografias de baixa dose, aliado a técnicas de IA, pode ser uma alternativa viável para avaliação do risco de câncer de mama.

No estudo de Squires *et al.*[196], avaliou a capacidade e a confiabilidade de modelos de DL para prever a densidade mamária em mamografias de baixa dose. Modelos treinados com dados simulados e reais foram testados em um conjunto com imagens emparelhadas, analisando fatores que influenciam a variação entre as predições em baixa e alta dose. Os resultados mostraram alta similaridade entre as predições, especialmente quando se combinam diferentes visões e modelos, embora mamas pequenas e densas apresentem maior variação. O uso de mamografias de baixa dose mostrou-se promissor para estimativas automáticas de densidade, com implicações positivas para o rastreamento precoce do câncer de mama em mulheres jovens.

4.4.7 - Detecção da distorção arquitetural

Foram identificados dois artigos com foco na detecção da distorção arquitetural desenvolvidos na China, que estão descritos na Tabela 16.

Tabela 16: IAs na identificação da distorção arquitetural

Aut or	Pa ís	Q t d e i m a g e n s	B a n c o s d e d a d o s	Modelos de IA	Objetivo	AU C	A c u r á c i a	Se ns ib ili d a d e	Es pe cif ici d a d e	V P P	V P N
160	Chin a	139 6	1	Mask-RCNN (Mask EfficientNetV 2, EfficientNetV 1, ResNext, ResNet	Detecção distorção arquitetural	89,00 %	84 %	74%	93%	N/ A	N/ A

197	China	298	1	ResNet50, Grad-CAM	Distorção arquitetural detectada na tomossíntese	82,00 %	74 %	68%	78%	N/A	N/A
-----	-------	-----	---	--------------------	--	---------	------	-----	-----	-----	-----

Fonte: Da autora (2025)


O estudo de Liu *et al.* [160] teve maior AUC 89%, acurácia 84%, especificidade de 74% e sensibilidade 93%. Este estudo desenvolveu e avaliou modelos de aprendizado profundo baseados na técnica *Mask Regional Convolutional Neural Network* (Mask-RCNN) para a identificação e diagnóstico de distorção arquitetural maligna em mamografias digitais. Um total de 1.396 imagens em projeção CC e MLO foram incluídos, e diferentes modelos de aprendizado de máquina foram comparados, destacando-se o EfficientNetV2, que apresentou a melhor performance. Os resultados indicam que esse modelo pode melhorar a precisão do diagnóstico da distorção arquitetural maligna, auxiliando radiologistas na detecção precoce do câncer de mama. As imagens foram inicialmente exportadas em formato DICOM e, para o pipeline, convertidas em PNG 16-bits, não foram mencionadas a inclusão de mamografias com implante mamário.

A pesquisa de Chen *et al.* [197] teve como objetivo avaliar o desempenho de duas abordagens de inteligência artificial (radiômica e aprendizado profundo) na detecção de distorções arquiteturais em imagens de tomossíntese mamária digital. Foram analisadas retrospectivamente 298 pacientes com diagnóstico confirmado por biópsia, das quais 175 apresentaram lesões malignas e 123 benignas. A abordagem radiômica utilizou regiões de interesse (ROIs) desenhadas manualmente nas vistas CC e MLO, enquanto o modelo de aprendizado profundo (ResNet50) usou as imagens completas. O modelo radiômico combinado apresentou maior acurácia (AUC=0.82) do que o modelo de deep learning (AUC=0.61), embora este último tenha demonstrado boa capacidade de localização das áreas suspeitas por meio de Grad-CAM. Os resultados sugerem que a radiômica pode ajudar a evitar biópsias desnecessárias, enquanto o deep learning pode contribuir para a segmentação automática das regiões suspeitas. Os autores informam que as imagens foram obtidas no sistema Fuji Film Amulet Innovality DBT, seguindo o protocolo clínico de radiologia e processadas por softwares como ImageJ e PyRadiomics, os quais operam diretamente sobre arquivos DICOM, não foi mencionado a inclusão de

pacientes com implantes mamários.

Na Figura 45 é demonstrado exemplos de casos mostrando a distorção arquitetural típica. Nas imagens A1 e A2 as incidências CC e MLO de uma paciente de 53 anos diagnosticada com carcinoma ductal invasivo. O escore BI-RADS é 4B. O escore radiômico do modelo combinado é 0,65, diagnosticando corretamente o caso como maligno (verdadeiro positivo). Nas imagens B1 e B2 as incidências CC e MLO de uma paciente de 42 anos diagnosticada com adenose esclerosante. O escore BI-RADS é 4C. O escore radiômico do modelo combinado é 0,48, diagnosticando corretamente o caso como benigno (verdadeiro negativo).

Figura 45 : Exemplos de casos mostrando a distorção arquitetural típica.



Fonte: [197]

4.4.8 - Segmentação para desenvolver IAs em mamografia

Foram encontrados 5 artigos que utilizaram a segmentação para diferentes objetivos, descritos na Tabela 17. Os autores Zahoor, Shoaib, Lali, [167] e Fu *et al*, [166] utilizaram a segmentação para massas mamárias. O autor Cortes-Rojas *et al*. [198] utilizou a segmentação para o músculo peitoral. Na pesquisa de Hong, Bhattacharyya, [199] na segmentação e realce de imagens de mamografias, por fim, Ghani *et al*. [201] na segmentação seletiva de anomalias

Tabela 17 - Segmentação para construção de IA

Au tor	País	Qtd e ima gen s	Ban cos de dad os	Model os de IA	Objeti vo	A U C	Ac ur ác ia	Se nsi bili da de	Esp eci fici da de	V P P	V P N
198	Méxic o	1288	MIAS	DeepLab v3+, ResNet- 50 como backbone	Segment ação músculo peitoral	N/ A	N/A	N/A	N/A	N/ A	N/ A
199	Índia	322	MIAS	SVM, MBH-IHF (Modified Bi-level Histogram with Homomo rphic Filter)	Segment ação e realce de imagens de mamogr afias	N/ A	N/A	N/A	N/A	N/ A	N/ A
200	China	não especí fica	não especí fica	UNet aprimora do	Segment ação de massas tumoriais	N/ A	N/A	N/A	N/A	N/ A	N/ A
201	Malási a	não especí fica	não especí fica	Self- Organizin g Map (SOM)	Segment ação seletiva de anomalia s	N/ A	96,0 0%	N/A	N/A	N/ A	N/ A
167	Paquis tão	2002	INbrea st, CBIS- DDSM	Skipping Dilated Semantic CNN	Segment ação de massas tumoriais	N/ A	98,9 5%	N/A	N/A	N/ A	N/ A

Fonte: Da autora (2025)

Não foram encontrados estudos que utilizaram a segmentação em implantes mamários.

4.4.9 - Outras categorias de IAs

Foram identificados quatorze outros objetivos que estão descritos na Figura 46, observa-se uma grande variedade de objetivos, porém todos voltados para a IA em mamografia.

Figura 46: Objetivos de outras categorias IA em mamografia



Fonte: Da autora (2025)

Na Tabela 18, estão descritos os objetivos de cada estudo, banco de imagens, modelos de IA utilizados e alguns autores avaliaram o potencial da IA com métricas.

Tabela 18 - Outras categorias de IAs em mamografia

A u t o r	Paí s	Qt de im ag ens	Ba nc os de da do s	Modelo s de IA	Objetiv o	A U C	A c u r á ci a	S e n si bi li da de	E s p e ci fi ci da de	V P P	V P N
190	Texas	3713	1	U-Net modificada	Viabilizar análises retroativa s de densidade	N/A	N/A	N/A	N/A	N/A	N/A

					e textura mamária						
202	Suíça	3034	1	Deep Convolutional Neural Network (dCNN)	Classificar opacidades de tecidos moles. Identificar posicionamento, lateralidade e classificar categoria BI-RADS 4	92,60%	100%	84%	100%	87,30%	N/A
203	Estados Unidos	3034	DDSM	ResNet-50	Classificação de opacidades	68%	53%	93%	N/A	N/A	N/A
204	Áustria	1888529	não específica	NYU1, NYU2	Avaliar a capacidade de generalização e replicação de modelos de deep learning	86%	N/A	54%	93%	N/A	N/A
205	Arábia Saudita	não específica	1	SM-INVIGOR, VAL-INVIGOR	Prognóstico para o câncer de mama	N/A	N/A	N/A	N/A	N/A	N/A
207	Arábia Saudita, Paquistão	156	MIAS	KNN, SVM, Linear Discriminant Analysis, Decision Tree Ensemble Classifier	IoMT para detectar câncer de mama	96,30%	98,60%	94,10%	N/A	N/A	N/A
208	Taiwan	156	MIAS	CNN personalizável, General Regression, Neural Networks (GRNN)	IoMT para detectar câncer de mama	N/A	93%	N/A	93%	N/A	96%
209	Portugal	1028	DDSM	Grammatical	Criar soluções	99,00%	N/A	N/A	N/A	N/A	N/A

				Evolution, SVM, Random Forests, Decision Trees	de classificação baseadas em evolução gramatical que sejam transparentes e compreensíveis						
210	Estados Unidos, Taiwan	205000	4	Mirai	Personalizar políticas de rastreamento de câncer de mama	N/A	N/A	N/A	N/A	N/A	N/A
211	Itália	364	2	Regressão logística, Árvores de decisão, Random Forest	Caracterização histológica de lesões mamárias com mamografia com contraste	95,83%	N/A	N/A	N/A	N/A	N/A
212	Irã	1824	Mini-MIAS, DDSM, Inbreast	PSOWNN8 e CNN	Melhorar a acurácia do diagnóstico de câncer de mama	95,43%	95,20%	98,60%	91,60%	N/A	N/A
213	Estados Unidos	961	MammoMass	Regressão logística penalidade elastic net, Extreme Gradient Boosting, Adaptive Ridge Regression Splines, SVM, Rede neural	Criar um passo a passo na criação de um uso de técnicas de ML	89,00%	N/A	N/A	N/A	N/A	N/A

214	Coreia do Sul	656	1	Lunit Insight MMG	Investigar os valores preditivos positivos (PPV) dos escores de um sistema comercial	N/A	N/A	N/A	N/A	N/A	96,30%
-----	---------------	-----	---	-------------------	--	-----	-----	-----	-----	-----	--------

Fonte: Da autora (2025)

Apenas dois artigos tiveram o mesmo objetivo que a IoMT para detectar câncer de mama. No estudo de Khan *et al.* [207] os autores propõem uma arquitetura de diagnóstico baseada na Internet das Coisas Médicas (IoMT) para a detecção remota de anomalias mamárias. Utilizando imagens do banco de dados MIAS, o sistema aplica algoritmos de crescimento de região para segmentar tumores, extraindo características texturais e morfológicas por meio de métodos estatísticos de primeira e segunda ordem, CS-LBP, HOG e análise geométrica. A classificação é realizada por diferentes algoritmos de aprendizado de máquina, com destaque para o classificador em ensemble, que obteve a melhor performance. A proposta visa oferecer um diagnóstico precoce e eficiente em áreas remotas, superando a escassez de radiologistas. A maior efetividade foi alcançada na classificação de lesões mamárias utilizando características de forma, com os seguintes resultados, Acurácia 96,3%, Sensibilidade 94,1% e Especificidade 98,2%. O estudo não menciona se foram incluídas imagens com implante mamário.

Na pesquisa de Chen *et al.* [208], teve uma acurácia e sensibilidade menor com 93%. O estudo propõe um sistema inteligente para segurança da informação e diagnóstico assistido por inteligência artificial no contexto de IoMTS. Utilizando sensores de ondas milimétricas para detectar sinais vitais e imagens médicas digitais, a pesquisa desenvolve um protocolo de criptografia simétrica baseado em mapas caóticos e na desigualdade de Bell, aliado a modelos de redes neurais de regressão (GRNN) para os processos de encriptação e desencriptação. Um classificador baseado em CNN é treinado para diagnosticar tumores mamários. Os testes experimentais validam a eficácia das abordagens tanto na proteção dos dados quanto na acurácia diagnóstica, com alta performance em métricas de segurança e classificação. O artigo não detalha os tipos específicos de patologias como nódulos,

calcificações ou carcinoma ductal in situ e não menciona se foram incluídas mamografias com implante mamário.


Na pesquisa de Hasan *et al.*[209] o AUC foi de 99%. Este estudo propõe uma abordagem inovadora para diagnóstico de câncer de mama a partir de imagens médicas, combinando o uso da Evolução Gramatical (GE) com uma técnica de aumento de dados recentemente introduzida chamada STEM. O objetivo é superar dois grandes desafios enfrentados por modelos de aprendizado de máquina na área da saúde: o desequilíbrio de classes e a interpretabilidade dos modelos. A abordagem foi testada em dois conjuntos de dados amplamente utilizados, o DDSM e o Wisconsin Breast Cancer (WBC). Os resultados indicam que os modelos gerados por GE, treinados com dados aumentados pelo STEM, não apenas alcançam desempenho superior em termos de AUC, como também oferecem soluções altamente interpretáveis, fundamentais em contextos clínicos. O estudo menciona a inclusão de imagens CC e MLO, porém não especifica a inclusão de imagens com implantes mamários, não especifica se as imagens estão em DICOM, o artigo não detalha os tipos específicos de patologias presentes nas imagens. Ele menciona apenas que foram utilizadas imagens cancerosas e saudáveis, sem especificar se os casos envolvem nódulos, calcificações ou carcinoma ductal in situ.

A maior acurácia apresentada foi na pesquisa de Hejduk *et al.*[206], este estudo teve como objetivo desenvolver e validar uma plataforma de IA para a avaliação automática da qualidade de imagem em mamografias e tomossíntese, considerando um conjunto padronizado de características. Foram analisadas 11.733 imagens mamográficas e reconstruções sintéticas 2D de tomossíntese de 4.200 pacientes. Modelos de redes neurais convolucionais profundas (dCNNs) foram treinados para detectar a presença de marcos anatômicos e características relacionadas à qualidade da imagem. Os resultados demonstraram uma alta precisão dos modelos, variando entre 93,0% e 98,5%, com escores de concordância de Cohen acima de 0,9 em comparação com radiologistas experientes. A implementação de um sistema automatizado de avaliação da qualidade permite um feedback em tempo real para técnicos e radiologistas, reduzindo exames inadequados, recalls desnecessários e servindo como uma plataforma de treinamento confiável.

Um exemplo de detecção quantitativa completa da mama do estudo de Hejduk, *et al.* (2023) é demonstrado na Figura 47. Detecção da posição do mamilo na imagem CC (a) e na imagem MLO (b); detecção das posições cranial (c) e caudal (d) do

músculo peitoral em uma imagem; cálculo dos comprimentos entre o músculo peitoral e o mamilo nas imagens CC (e) e MLO (f); cálculo do ângulo do músculo peitoral (g); e cálculo do nível entre o músculo peitoral e o mamilo.

Figura 47: Exemplo de detecção quantitativa completa da mama:




Fonte: [206]

Sabani *et al.* [202] apresentou 100% de especificidade e VPP. Este estudo investigou o uso de uma dCNN para classificar opacidades de tecidos moles em mamografias com base no sistema BI-RADS. Foram analisadas 1.744 mamografias de 438 pacientes. A dCNN atingiu uma precisão de até 89,8% e demonstrou desempenho comparável ao de radiologistas experientes, com maior especificidade na detecção de lesões suspeitas. O uso de mapas de probabilidade permitiu a visualização da distribuição das lesões, tornando a abordagem mais interpretável. Os resultados indicam que a dCNN pode ser uma ferramenta valiosa na detecção automatizada do câncer de mama, auxiliando na tomada de decisão clínica.

Na Figura 48 é demonstrado o estudo de Sabani, et al. (2022) com imagens mamográficas das três classes BI-RADS definidas: (a) “tecido saudável”, (b) “opacidade de tecido mole provavelmente benigna” e (c) “opacidade de tecido mole suspeita”, com ampliação da região de interesse (ROI).

Figura 48: Ilustração mamográfica das três classes BI-RADS definidas:



Fonte: [202]

A análise de todas as categorias artigos evidenciou que a produção científica sobre IA em mamografia apresenta um avanço significativo em termos de diversidade temática e metodológica, refletindo a consolidação desse campo como uma das áreas mais dinâmicas da radiologia moderna. Os estudos analisados revelam predominância nas linhas de pesquisa voltadas à detecção e classificação do câncer de mama, com destaque para modelos baseados em DL e CNNs, que atingiram métricas expressivas de desempenho. Pesquisas como as de McKinney *et al.* [24] e Wan *et al.* [107] demonstram que algoritmos bem treinados podem alcançar acurácia e AUC comparáveis ou superiores à leitura humana, consolidando a IA como ferramenta de apoio diagnóstico complementar ao radiologista.

Os avanços técnicos mais consistentes foram observados em modelos híbridos e em abordagens que utilizam aprendizado por transferência e aumento de dados para superar a escassez de amostras rotuladas. Estudos como o de Salama *et al.* [119] e Alhussan *et al.* [124] ilustram esse progresso, alcançando métricas acima de 98% de AUC e acurácia, ao empregar arquiteturas como ResNet50 combinadas com SVM e otimizadores baseados em algoritmos evolucionários. Esse cenário

evidencia a maturidade metodológica do campo e a tendência de convergência entre precisão diagnóstica e aplicabilidade clínica. Contudo, a ausência de padronização na apresentação das métricas, principalmente VPP, VPN, sensibilidade e especificidade, ainda limita a comparação direta entre modelos e dificulta sua validação em contextos reais de rastreamento mamográfico [60].

Nas categorias de microcalcificações e massas mamárias, verificou-se menor volume de publicações, mas alta qualidade metodológica. Os estudos de Leong *et al.* [158] e Pesapane *et al.* [161] obtiveram AUC acima de 97%, demonstrando a relevância do pré-processamento, da segmentação precisa e da escolha adequada da arquitetura neural. No entanto, observou-se carência de padronização em relação às projeções utilizadas (CC e MLO) e ao formato das imagens (DICOM ou JPEG), o que compromete a reprodutibilidade dos resultados e a extrapolação dos achados para cenários clínicos mais complexos. Essa limitação reforça a necessidade de protocolos unificados e de bancos de dados abertos multicêntricos, que contemplem maior diversidade de equipamentos, parâmetros técnicos e perfis demográficos [64].

As áreas menos recorrentes, como detecção de distorção arquitetural e segmentação aplicada à construção de IAs, representam importantes lacunas de pesquisa. Apenas dois artigos foram encontrados com foco em distorção arquitetural, ambos desenvolvidos na China, utilizando abordagens distintas como radiômica e deep learning, com resultados promissores, mas ainda limitados [160], [197]. Da mesma forma, os estudos que exploram a segmentação, fundamental para delimitar regiões anatômicas e treinar modelos explicáveis, permanecem restritos e pontuais. Tal cenário demonstra que, embora o campo da IA em mamografia tenha avançado em desempenho, ainda carece de maior ênfase na interpretabilidade e explicabilidade dos algoritmos, aspectos fundamentais para a aceitação clínica e ética desses sistemas [1].

Outra limitação identificada refere-se à representatividade demográfica e geográfica dos bancos de dados utilizados. A maioria das pesquisas foi conduzida com imagens provenientes da América do Norte e Europa, resultando em modelos potencialmente enviesados e pouco generalizáveis. A sub-representação de populações latino-americanas, africanas e asiáticas compromete a equidade algorítmica e pode impactar o desempenho dos sistemas em populações diversas [110]. Outro ponto relevante é que poucos estudos especificaram o uso de imagens com implantes mamários ou de baixa dose, aspectos relevantes para a aplicabilidade

clínica ampla. Essa homogeneidade de dados representa uma das principais barreiras à generalização e validação externa dos modelos de IA.

Em síntese, o panorama atual indica um movimento de consolidação das pesquisas sobre IA em mamografia, com foco crescente na integração de sistemas híbridos, modelos preditivos e ferramentas explicáveis. As tendências mais recorrentes apontam para a busca de acurácia elevada aliada à eficiência operacional, enquanto as lacunas evidenciam a sugestões de colaborações multicêntricas, validações externas padronizadas e construção de datasets multiétnicos. A próxima geração de algoritmos deve priorizar não apenas o desempenho técnico, mas também a transparência, reprodutibilidade e ética no uso da IA. Assim, o futuro do rastreamento mamográfico com IA dependerá da capacidade da comunidade científica de equilibrar inovação tecnológica e equidade diagnóstica, garantindo avanços sustentáveis e aplicáveis à prática radiológica global [60], [1].

5. CONCLUSÃO

A análise abrangente da produção científica internacional sobre o uso da IA em mamografia revela uma expansão significativa das publicações nos últimos cinco anos, com maior concentração nos anos de 2023 e 2024. Esse crescimento é impulsionado, sobretudo, por países com elevada infraestrutura tecnológica, como Estados Unidos, Índia, Reino Unido e China, que concentram a maioria dos bancos de dados empregados no treinamento e validação dos algoritmos. Essa centralização geográfica, embora tenha promovido avanços técnicos notáveis, reforça uma assimetria científica que limita a generalização e a equidade diagnóstica dos modelos, especialmente em populações sub-representadas de regiões latino-americanas e africanas [59], [60].

Sob a perspectiva técnica, observou-se predominância de estudos baseados em mamografia digital, enquanto a aplicação da tomossíntese na modelagem de IA ainda se encontra em estágios iniciais, configurando-se como um campo promissor de investigação. Destaca-se, ainda, a recorrência de fabricantes como Hologic, GE e Siemens, o que evidencia dependência tecnológica e risco de viés de dispositivo. Tal concentração reforça a necessidade de diversificação dos equipamentos utilizados, bem como de estudos comparativos que examinem o impacto das variações de hardware e software sobre o desempenho diagnóstico dos modelos.

A análise dos bancos de dados disponíveis indica uma diversidade étnica apenas moderada, com evidente sub-representação de mulheres afrodescendentes e asiáticas. Essa limitação compromete a validação e a generalização dos modelos de IA, restringindo sua aplicabilidade em contextos clínicos plurais. Entre os conjuntos de dados amplamente reconhecidos e aceitos pela FDA destacam-se o DDSM, o CBIS-DDSM, o INbreast, o OPTIMAM e o MIAS, que figuram entre os mais utilizados na construção e validação de algoritmos. Recomenda-se, contudo, a ampliação da abrangência desses bancos, incluindo mamografias com contraste e imagens de pacientes com implantes mamários, uma vez que tais características influenciam a leitura automatizada e permanecem pouco representadas na literatura analisada.

Em relação ao desempenho comparativo entre IA e radiologistas, constatou-se que os resultados mais promissores decorrem de abordagens colaborativas, nas

quais a IA atua como ferramenta de apoio à decisão e não como substituta do profissional. Essa complementaridade reflete uma mudança paradigmática, posicionando a IA como uma “segunda leitura” ou sistema de triagem inteligente capaz de aprimorar a sensibilidade e a especificidade diagnóstica, reduzindo simultaneamente as taxas de falsos positivos. Contudo, a limitação no número de radiologistas avaliadores constitui um fator metodológico relevante, pois impacta diretamente a acurácia das métricas e restringe a aplicabilidade dos algoritmos em cenários clínicos heterogêneos.

As tendências identificadas na literatura indicam predomínio de pesquisas voltadas à detecção e classificação do câncer de mama, com ênfase em modelos de DL e CNNs, que alcançaram métricas expressivas de desempenho. Os avanços mais consistentes foram observados em modelos híbridos e abordagens que empregam aprendizado por transferência e técnicas de aumento de dados para mitigar a escassez de amostras rotuladas. Entretanto, a ausência de padronização na apresentação das métricas, especialmente valor preditivo positivo (VPP), valor preditivo negativo (VPN), sensibilidade e especificidade, limita a comparabilidade entre estudos e dificulta a translação dos resultados para contextos clínicos reais. Por fim, verificou-se menor número de publicações em áreas como microcalcificações, massas mamárias, detecção de distorção arquitetural, mamografia com contraste, implantes mamários e mamografia de baixa dose. Embora menos recorrentes, tais temas apresentam alta relevância metodológica e representam lacunas significativas para futuras investigações. A homogeneidade dos dados e a baixa representatividade de determinados subgrupos clínicos e demográficos configuram-se, portanto, como os principais obstáculos à generalização e à validação externa dos modelos de IA em mamografia.

Resumidamente é possível identificar que o primeiro objetivo, de identificar as principais limitações das tecnologias de IA na detecção precoce do câncer de mama, foi atingido ao evidenciar-se que a homogeneidade dos bancos de dados e a sub-representação étnica constituem barreiras à generalização dos modelos. O segundo objetivo, de comparar o desempenho diagnóstico da IA e dos radiologistas, demonstrou que abordagens colaborativas, nas quais a IA atua como suporte à decisão, obtêm melhor desempenho e maior confiabilidade clínica. O terceiro objetivo, voltado ao mapeamento das tendências de pesquisa, revelou o predomínio de estudos com modelos baseados em CNNs e DL, além do avanço de técnicas híbridas

e de transferência de aprendizado como soluções para a limitação de amostras rotuladas e os principais objetivos em detectar e classificar o câncer de mama. Por fim, o quarto objetivo, de identificar os principais bancos de dados utilizados, foi alcançado mediante a caracterização dos datasets mais citados (DDSM, CBIS-DDSM, INbreast, OPTIMAM e MIAS) e pela constatação da necessidade de ampliação da diversidade demográfica e técnica, incluindo mamografias com contraste e com implantes mamários.

REFERÊNCIAS

- [1]- WORLD HEALTH ORGANIZATION (WHO). **Artificial Intelligence in Health: Ethics and Governance of Artificial Intelligence for Health**. Geneva: WHO, 2023.
- [2]- BRASIL. Ministério da Saúde. Instituto Nacional de Câncer José Alencar Gomes da Silva (INCA). **Detecção precoce do câncer de mama**. Rio de Janeiro: INCA, 2022. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-cancer-de-mama/acoes/deteccao-precoce>
- [3]- ORGANIZAÇÃO MUNDIAL DA SAÚDE. **Ethics and governance of artificial intelligence for health**. Geneva: World Health Organization, 2021. Disponível em: <https://www.who.int/publications/i/item/9789240029208>. Acesso em: 18 out. 2025.
- [4] - BRASIL. Ministério da Saúde. **Ministério da Saúde garante acesso à mamografia a partir dos 40 anos**. Brasília: Ministério da Saúde, 2025. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/noticias/2025/setembro/ministerio-da-saude-garante-acesso-a-mamografia-a-partir-dos-40-anos>. Acesso em: 2 out. 2025
- [5]- STANDRING, Susan, e Henry Gray, organizadores. **Gray's Anatomy: The Anatomical Basis of Clinical Practice**. 40. ed., Anniversary ed., 1. print, Churchill Livingstone Elsevier, 2008.
- [6]- BONTRAGER, K. L.; LAMPIGNANO, J. P. **Tratado de Posicionamento Radiográfico e Anatomia Associada**. 8. ed. [s.l.] Elsevier Editora Ltda, 2015.
- [7] - BRASIL. Ministério da Saúde. Instituto Nacional do Câncer José Alencar Gomes da Silva. **Atualização em mamografia para técnicos em radiologia**. – 2. ed. rev. atual. Rio de Janeiro: INCA, 2019.
- [8]- BUSHONG, Stewart C. **Radiologic Science for Technologists: Física Radiológica, Biologia e Proteção Radiológica**. 9. ed. Rio de Janeiro: Elsevier, 2010.
- [9]- BRASIL. INSTITUTO NACIONAL DE CÂNCER. **Controle do câncer de mama no Brasil: dados e números: 2024**. Rio de Janeiro: INCA, 2024. 69 p. Disponível em: <https://ninho.inca.gov.br/jspui/handle/123456789/17002>. Acesso em: 8 out. 2025.
- [10]- BRASIL. MINISTÉRIO DA SAÚDE/INCA, 16 set.2022. **Detecção precoce do câncer de mama**. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-cancer-de-mama/acoes/deteccao-precoce>. Acesso em: 18/06/2023.
- [11]- BRASIL. Ministério da Saúde. Instituto Nacional do Câncer José Alencar Gomes da Silva. **Atualização em mamografia para técnicos em radiologia**. – 2. ed. rev. atual. Rio de Janeiro: INCA, 2019
- [12]- INTERNATIONAL ATOMIC ENERGY AGENCY (IAEA). Quality assurance

programme for digital mammography. Vienna: IAEA, 2011. (IAEA Human Health Series, n. 17). Disponível em: <https://www.iaea.org/publications/8738/quality-assurance-programme-for-digital-mammography>.

[13] BRASIL. **Cadastro Nacional de Estabelecimentos**. Disponível em: [CnesWeb - Cadastro Nacional de Estabelecimentos de Saúde \(datasus.gov.br\)](https://cnesweb.datasus.gov.br/). Acesso em 09/08/2023

[14] MARQUES DA SILVA, A. M.; PATROCÍNIO, A. C.; SCHIABEL, H. **Processamento e Análise de Imagens Médicas**. Revista Brasileira de Física Médica, v. 13, n. 1, p. 34, 2019.

[15] BRASIL. Ministério da Saúde. Instituto Nacional de Câncer. **Mamografia: da prática ao controle**. Rio de Janeiro, 2007. 109p. : il. tab.; 18,0 X 25,0cm.

[16] EKLUND, G. W. et al. **Improved imaging of the augmented breast**. AJR. American journal of roentgenology, v. 151, n. 3, p. 469–473, 1988.

[17] DA SILVA, A. C. F. et al. **Coeficientes de Conversão do Kerma no Ar Incidente para a Dose Glandular Média em Mamografia de Mulheres com Implantes Mamários**: Estudo Preliminar. Revista Brasileira de Física Médica, v. 13, n. 2, p. 25, 2019.

[18] SHAH, B. A.; JANKHARIA, B. Imaging of breast implants – a pictorial essay. **Indian Journal of Radiology and Imaging**, v. 26, n. 2, p. 216–225, 2016.

[19] SICKLES, EA, D'Orsi CJ, Bassett LW, et al. Mamografia ACR BI-RADS® . In: **ACR BI-RADS® Atlas, Sistema de Relatórios e Dados de Imagens da Mama**. Reston, VA, Colégio Americano de Radiologia; 2013.

[20] **INTERNATIONAL COMMISSION ON RADIATION UNITS AND MEASUREMENTS**. *Mammography: an image quality and dose perspective*. Bethesda, MD: ICRU, 2015. (ICRU Report 85, *Journal of the ICRU*, v. 14, n. 1).

[21] LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. **Deep learning**. Nature, London, v. 521, n. 7553, p. 436–444, 2015. DOI: 10.1038/nature14539.

[22] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

[23] LITJENS, G.; KOOI, T.; BEJNORDI, B. E.; et al. **A survey on deep learning in medical image analysis**. Medical Image Analysis, v. 42, p. 60-88, 2017.

[24] MCKINNEY, SM; SIENIEK, M; GODBOLE, V et al. **International evaluation of an AI system for breast cancer screening**. NATURE, jan. 2020. DOI: 10.1038/s41586-019-1799-6.

[25] **UNITED STATES**. Food and Drug Administration. *Artificial Intelligence/Machine Learning (AI/ML)-Based Software as a Medical Device (SaMD) Action Plan*. Silver Spring, MD: Center for Devices and Radiological Health, 2022. Disponível em:

<https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-software-medical-device>. Acesso em: 18 out. 2025.

[26] TAYLOR CR, Monga N, Johnson C, Hawley JR, Patel M. **Aplicações de Inteligência Artificial em Imagens de Mama: Status Atual e Direções Futuras**. Diagnóstico (Basileia). 13 de junho de 2023; 13(12):2041. DOI: 10.3390/diagnostics13122041. PMID: 37370936; PMCID: PMC10296832.

[27] SHICKEL, B. et al. **Deep EHR: A Survey of Recent Advances in Deep Learning** Techniques for Electronic Health Record (EHR) Analysis. IEEE Journal of Biomedical and Health Informatics, v. 22, n. 5, p. 1589–1604, 2018. DOI: 10.1109/JBHI.2017.2767063.

[28] SHEN, D.; WU, G.; SUK, H. I. **Deep Learning in Medical Image Analysis**. *Annual Review of Biomedical Engineering*, v. 19, p. 221–248, 2017. DOI: 10.1146/annurev-bioeng-071516-044442.

[28] MINH, T. H. et al. **Deep Learning for Computer Vision: A Brief Review**. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 37, n. 9, p. 179–195, 2015.

[29] HOSNY, A. et al. **Artificial Intelligence in Radiology**. *Nature Reviews Cancer*, v. 18, n. 8, p. 500–510, 2018. DOI: 10.1038/s41568-018-0016-5.

[30] RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: **Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015**. Lecture Notes in Computer Science, v. 9351. Cham: Springer, 2015. p. 234–241. DOI: 10.1007/978-3-319-24574-4_28.

[31] TOPOL, E. **Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again**. Nova Iorque: Basic Books, 2019.

[32] DHUNGEL, N.; CARNEIRO, G.; BRADLEY, A. P. Deep Learning and Structured Prediction for the Segmentation of Mass in Mammograms. In: **Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015)**. Lecture Notes in Computer Science, v. 9351. Cham: Springer, 2015. p. 605–612. DOI: 10.1007/978-3-319-24553-9_74.

[33] SHEN, L.; MARGOLIS, R.; ROTH, H. R.; MULLER, H.; SUMKIN, J. H.; NISHIKAWA, R. M. **Deep Learning to Improve Breast Cancer Detection on Screening Mammography**. Scientific Reports, v. 7, n. 1, p. 1–12, 2017. DOI: 10.1038/s41598-017-10832-4.

[34] RIBLI, D.; HORVÁTH, A.; UNGER, Z.; POLONYI, S.; CSAIBA, I. **Detecting and Classifying Lesions in Mammograms with Deep Learning**. *Scientific Reports*, v. 8, n. 1, p. 1–7, 2018. DOI: 10.1038/s41598-018-22437-z.

[35] ZHU, W. et al. **Deep Mammography Mass Detection and Classification Using Convolutional Neural Networks**. *Pattern Recognition*, v. 98, p. 107–120,

2019. DOI: 10.1016/j.patcog.2019.107075.

[36] ARAVIND, P. *et al.* **Deep Learning-Based Recurrent Neural Networks for Breast Cancer Detection Using Mammogram Images.** *Diagnostics*, v. 14, n. 2, p. 215, 2024. DOI: 10.3390/diagnostics14020215.

[37] AHMED, M. U. *et al.* Deep Hybrid Convolutional-Recurrent Neural Network Framework for Breast Cancer Detection Using Mammographic Images. *Sensors*, v. 24, n. 6, p. 1825, 2024. DOI: 10.3390/s24061825.

[38] VELARDE, C. A. *et al.* Recurrent Neural Networks with Attention Mechanisms for Automated Mammogram Classification. *Diagnostics*, v. 14, n. 4, p. 512, 2024. DOI: 10.3390/diagnostics14040512.

[39] LAMBIN, P.; RIOS-VELAZQUEZ, E.; LEIJENAAR, R.; CARVALHO, S.; STIPHOUT, R. V.; GRANTON, P.; *et al.* **Radiomics: extracting more information from medical images using advanced feature analysis.** *European Journal of Cancer*, v. 48, n. 4, p. 441-446, 2012.

[40] GUO, Zhen; SHU, Yan; ZHOU, Hong-Hao; ZHANG, Wei; WANG, Hui. **A radiogenômica ajuda a alcançar a terapia personalizada, avaliando as respostas do paciente ao tratamento com radiação.** *Carcinogênese*, v. 36, n. 3, p. 307-317, 2015. DOI: 10.1093/CARCIN/BGV007.

[41] B.; FORSTER, K.; AERTS, H. J. W. L.; DEKKER, A.; FENSTERMACHER, D.; GOLGDOF, D. B.; HALL, L. O.; LAMBIN, P.; BALAGURUNATHAN, Y.; GATENBY, R. A.; GILLIES, R. J. **Radiomics: the process and the challenges.** *Magnetic Resonance Imaging*, v. 30, n. 9, p. 1234-1248, 2012.

[42] LAMBIN, P.; RIOS-VELAZQUEZ, E.; LEIJENAAR, R.; CARVALHO, S.; STIPHOUT, R. V.; GRANTON, P.; *et al.* **Radiomics: extracting more information from medical images using advanced feature analysis.** *European Journal of Cancer*, v. 48, n. 4, p. 441-446, 2012.

[43] DROMAIN, C.; THIBAUT, F.; DIEKMANN, F.; FALLENBERG, E. M.; SINGH, J. M.; TOURNOUX-FRANK, V.; BERG, W. A. **Computer-Aided Diagnosis (CAD) in the Detection and Characterization of Breast Lesions: Fundamentals and Clinical Data.** *European Journal of Radiology*, Amsterdam, v. 82, n. 3, p. 448–455, 2013. DOI: 10.1016/j.ejrad.2012.11.019.

[44] RODRÍGUEZ-RUIZ, A.; LANG, K.; GOLDBERG, M.; GIGER, M.; HEEJIN, J.; MANN, R. M.; SECHOUX, I.; KARSSEMEIJER, N. **Detection of Breast Cancer with Mammography: Effect of an Artificial Intelligence Support System.** *European Radiology*, Berlin, v. 29, n. 10, p. 5458–5468, 2019. DOI: 10.1007/s00330-019-06186-7.

[45] DOUQI, T.; KHAN, S.; MAHMOOD, A. **Preprocessing techniques in mammography for breast cancer detection: A review.** *Journal of Imaging Science and Technology*, v. 64, n. 5, p. 1-12, 2020. DOI: 10.2352/J.ImagingSci.Technol.2020.64.5.050505.

[46] SILVA, Eduarda Passig e. **Detecção de nódulos em imagens de mamografia usando Wavelet e Inteligência Artificial**. 2023. Trabalho de Conclusão de Curso (Engenharia de Telecomunicações) – Instituto Federal de Santa Catarina, São José, 2023. Orientadora: Elen Macedo Lobato. Coorientador: Ramon Mayor Martins

[47] ANSAR, Wajeeha; RAZA, Basit. **Breast cancer segmentation in mammogram using artificial intelligence and image processing: a systematic review**. *Current Chinese Science*, 2022. DOI: 10.2174/2210298102666220406121814.

[48] GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 3. ed. Pearson Prentice Hall, 2008.

[49] WATANABE, Carolina Yukari Veludo. **Métodos de apoio ao diagnóstico médico por imagens usando regras de associação e redes complexas**. 2013. 128 f. Tese (Doutorado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2013.

[50] SOUZA, R. T. F.; PINA, D. R.; ALVAREZ, M.; VELO, A. F.; OLIVEIRA, M.; PAVAN, A. L. M.; MIRANDA, J. R. A. **Quantificação de tecidos em imagens mamográficas por meio de histogramas**. *Revista Brasileira de Física Médica*, v. 6, n. 2, p. 173–177, 2012.

[51] WHITTEMORE, R.; KNAFL, K. **The integrative review: updated methodology**. *Journal of Advanced Nursing*, v. 52, n. 5, p. 546–553, 2005. <https://doi.org/10.1111/j.1365-2648.2005.03621.x>

[52] FLICK, U. **Introdução à pesquisa qualitativa**. 3. ed. Porto Alegre: Artmed, 2009.

[53] FLICK, U. **Desenho da pesquisa qualitativa**. Porto Alegre: Artmed, 2013.

[54] BOTELHO, Liziane Lins; CUNHA, Cecília Cristina da; MACEDO, Marli de Carvalho. **O método da revisão integrativa nos estudos organizacionais**. *Revista Eletrônica Gestão & Sociedade*, v. 5, n. 11, p. 121–136, 2011.

[55] BARDIN, Laurence. **Análise de conteúdo**. Tradução: Luís Antero Reto e Augusto Pinheiro. São Paulo: Edições 70, 2011. 229 p.

[56] DATACAMP. Tutorial do RStudio para iniciantes: Um guia completo. Disponível em: <https://www.datacamp.com/pt/tutorial/r-studio-tutorial>. Acesso em: 9 out. 2025

[57] **R CORE TEAM**. *R: A language and environment for statistical computing*. Vienna: R Foundation for Statistical Computing, 2025. Disponível em: <https://www.r-project.org/>. Acesso em: 19 out. 2025.

[58] **RSTUDIO TEAM**. *RStudio: Integrated Development Environment for R*. Boston: Posit Software, PBC, 2023. Disponível em: <https://posit.co/>. Acesso em: 19 out. 2025.

- [59] YALA, A. et al. **Toward Fairness in Artificial Intelligence for Mammography Screening: Challenges and Future Directions**. *Nature Medicine*, v. 28, p. 2437–2448, 2022b.
- [60] MCDERMOTT, M. B. A. et al. **Reproducibility in Machine Learning for Health Research: Still a Challenge Despite Progress**. *Nature Medicine*, v. 29, p. 149–160, 2023.
- [61] LEWIS, S. J. et al. **Artificial Intelligence in Breast Imaging: A Global Perspective on Challenges and Opportunities**. *Radiology*, v. 307, n. 2, p. 346–359, 2023.
- [62] REGLAB. **Uso de ferramentas de proteção de dados para IA é baixo no Brasil**. *Inforchannel*, São Paulo, 2 out. 2025. Disponível em: <https://inforchannel.com.br/2025/10/02/uso-de-ferramentas-de-protecao-de-dados-para-ia-e-baixo-no-brasil-diz-reglab/>. Acesso em: 9 out. 2025.
- [63] CARVALHO, Geovanna Pozzebon et al. **A avaliação da precisão diagnóstica de algoritmos de inteligência artificial em mamografias digitais para detecção precoce de câncer de mama**. *Brazilian Journal of Implantology and Health Sciences*, v. 6, n. 8, p. 5065–5072, 2024.
- [64] FRAZER, HML; TANG, JSN; ELLIOTT, MS et al.. **ADMANI: Annotated Digital Mammograms and Associated Non-Image Datasets**. *RADIOLOGY-ARTIFICIAL INTELLIGENCE*, mar. 2023. DOI: 10.1148/ryai.220072.
- [65] KHALED, Rana; HELAL, Maha; ALFARGHALY, Omar et al.. **Categorized contrast enhanced mammography dataset for diagnostic and artificial intelligence research**. *Sci Data*, mar. 2022. DOI: 10.1038/s41597-022-01238-0.
- [66] IMANE, O; MOHAMED, A; LAZHAR, RF et al.. **LAMIS-DMDB: A new full field digital mammography database for breast cancer AI-CAD researches**. *BIOMEDICAL SIGNAL PROCESSING AND CONTROL*, abr. 2024. DOI: 10.1016/j.bspc.2023.105823.
- [67] DAHLBLOM, V; DUSTLER, M; BOLEJKO, A et al.. **Malmo Breast ImagingG database: objectives and development**. *JOURNAL OF MEDICAL IMAGING*, nov. 2023. DOI: 10.1117/1.JMI.10.6.061402.
- [68] AQDAR, Karzan Barzan; MUSTAFA, Rawand Kawa; ABDULQADIR, Zhiyar Hamid et al.. **Mammogram mastery: A robust dataset for breast cancer detection and medical education**. *Data in brief*, ago. 2024. DOI: 10.1016/j.dib.2024.110633.
- [69] OSUALA, R; SKORUPKO, G; LAZRAK, N et al.. **medigan: a Python library of pretrained generative models for medical image synthesis**. *JOURNAL OF MEDICAL IMAGING*, nov. 2023. DOI: 10.1117/1.JMI.10.6.061403.
- [70] JEONG, JJ; VEY, BL; BHIMIREDDY, A et al.. **The EMory BrEast imaging Dataset (EMBED): A Racially Diverse, Granular Dataset of 3.4 Million Screening**

and Diagnostic Mammographic Images. RADIOLOGY-ARTIFICIAL INTELLIGENCE, jan. 2023. DOI: 10.1148/ryai.220047.

[71] MONTEIRO CORDEIRO, Natália; FACINA, Gil; PINTO NAZÁRIO, Afonso Celso et al.. **Towards precision medicine in breast imaging: A novel open mammography database with tailor-made 3D image retrieval for AI and teaching.** Comput Methods Programs Biomed, mar. 2024. DOI: 10.1016/j.cmpb.2024.108117.

[72] McCONNELL, Michael V. et al. The importance of diversity and inclusion in artificial intelligence for healthcare. **The Lancet Digital Health**, v. 3, n. 8, p. e470–e471, 2021. DOI: 10.1016/S2589-7500(21)00161-6

[73] SESSA, Sara; KIM, Eun Ji; YALA, Adam. Mitigating bias in artificial intelligence for breast cancer screening: Current challenges and future directions. **npj Breast Cancer**, v. 9, n. 1, p. 1–8, 2023. DOI: 10.1038/s41523-023-00501-0

[74] GICHUHI, Susan; KANODIA, Jaspreet; SHEIKH, Aziz. **Ethical artificial intelligence for global health: The case for diversity in data and design.** BMJ Global Health, v. 7, n. 4, e008456, 2022. DOI: 10.1136/bmjgh-2021-008456

[75] Mendes, J. R.; Silva, L. P.; Ferreira, T. C. (2022). Artificial intelligence in breast imaging: challenges of dataset diversity and equity in algorithmic performance. **Journal of Digital Imaging**, v. 35, n. 4, p. 812–825, 2022. DOI: 10.1007/s10278-022-00635-1.

[76] Lee, C. I.; Yala, A.; Barzilay, R. (2021). Representation of patient diversity in artificial intelligence models for breast cancer screening. **Radiology: Artificial Intelligence**, v. 3, n. 4, p. e210006, 2021. DOI: 10.1148/ryai.2021210006.

[77] COSSÍO, Fernando; SCHURZ, Haiko; ENGSTRÖM, Mathias; BARCK-HOLST, Carl; TSIRIKOGLOU, Apostolia; LUNDSTRÖM, Claes; GUSTAFSSON, Håkan; SMITH, Kevin; ZACKRISSON, Sophia; STRAND, Fredrik. VAI-B: uma plataforma multicêntrica para validação externa de algoritmos de inteligência artificial em imagens mamárias. **Journal of Medical Imaging (Bellingham)**, v. 10, n. 6, p. 061404, nov. 2023. DOI: 10.1117/1.JMI.10.6.061404.

[78] TAN, Mingxing; LE, Quoc V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In: **Proceedings of the 36th International Conference on Machine Learning (ICML)**. Long Beach, CA: PMLR, 2019. p. 6105–6114. Disponível em: <https://arxiv.org/abs/1905.11946>. Acesso em: 19 out. 2025.

[79] SELVARAJU, R. R. et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization. **Proceedings of the IEEE International Conference on Computer Vision (ICCV)**, Venice, p. 618–626, 2017. DOI: 10.1109/ICCV.2017.74.

[80] GOODFELLOW, Ian J. et al. Generative adversarial nets. In: **Proceedings of the 27th International Conference on Neural Information Processing Systems**

(NIPS 2014). Montreal: MIT Press, 2014. p. 2672–2680.

[81] GOODFELLOW, Ian J. et al. Generative Adversarial Nets. In: **Advances in Neural Information Processing Systems (NeurIPS 2014)**. Montreal, Canada: Curran Associates, 2014. p. 2672–2680.

[82] ISOLA, Phillip; ZHU, Jun-Yan; ZHOU, Tinghui; EFROS, Alexei A. Image-to-Image Translation with Conditional Adversarial Networks. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017)**. Honolulu, HI: IEEE, 2017. p. 5967–5976

[83] ZHU, Jun-Yan; PARK, Taesung; ISOLA, Phillip; EFROS, Alexei A. Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. In: **Proceedings of the IEEE International Conference on Computer Vision (ICCV 2017)**. Venice, Italy: IEEE, 2017. p. 2223–2232.

[84] GULRAJANI, Ishaan et al. **Improved Training of Wasserstein GANs**. In: **Advances in Neural Information Processing Systems (NeurIPS 2017)**. Long Beach, CA: Curran Associates, 2017. p. 5767–5777.

[85] SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. In: **International Conference on Learning Representations (ICLR)**, 2015. Disponível em: <https://arxiv.org/abs/1409.1556>. Acesso em: 19 out. 2025.

[86] DEVLIN, Jacob et al. **BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding**. Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics (NAACL), p. 4171–4186, 2019.

[87] KIM, H. E. et al. **Changes in cancer detection and false-positive recall in mammography using artificial intelligence: a retrospective, multireader study**. The Lancet Digital Health, v. 2, n. 3, p. e138–e148, 2020.

[88] SCHILLING, K. et al. **Artificial Intelligence as a Second Reader for Radiologists in Mammography Screening: A Retrospective Multicenter Study**. European Radiology, v. 31, p. 959–967, 2021.

[89] LEMAITRE, G. et al. **Vara AI for Breast Cancer Screening: Real-world Performance in a National Population-based Program**. Radiology: Artificial Intelligence, v. 4, n. 6, p. e210175, 2022.

[90] CHIWOME, Lawman et al. **Artificial Intelligence: Is It Armageddon for Breast Radiologists? Cureus**, v. 12, n. 6, p. e8923, 2020. DOI: 10.7759/cureus.8923. Disponível em: <https://www.cureus.com/articles/8923>. Acesso em: 11 out. 2025.

[91] MCKINNEY, S. M. et al. International evaluation of an AI system for breast cancer screening. **Nature**, v. 577, p. 89-94, 2020. Disponível em: <https://doi.org/10.1038/s41586-019-1799-6>. Acesso em: 11 out. 2025.

[92] BIOINFO. Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e F-score. **Revista Brasileira de Bioinformática**, edição #01, jul. 2021. Disponível em: <https://bioinfo.com.br/metricas-de-avaliacao-em-machine-learning-acuracia-sensibilidade-precisao-especificidade-e-f-score/>. Acesso em: 29 set. 2025.

[93] RESUMOS MEDICINA. **Curva ROC e AUC: o guia definitivo para avaliar a acurácia de testes diagnósticos**. 2025. Disponível em: <https://www.resumosmedicina.com.br/blog/curva-roc-e-auc-o-guia-definitivo-para-avaliar-a-acuracia-de-testes-diagnosticos>. Acesso em: 29 set. 2025.

[94] NOWAKOWSKA, S; VESCOLI, V; SCHNITZLER, T et al.. **Technical feasibility of automated blur detection in digital mammography using convolutional neural network**. EUROPEAN RADIOLOGY EXPERIMENTAL, nov. 2024. DOI: 10.1186/s41747-024-00527-0.

[95] HELAL, Maha; KHALED, Rana; ALFARGHALY, Omar et al.. **Validation of artificial intelligence contrast mammography in diagnosis of breast cancer: Relationship to histopathological results**. Eur J Radiol, mar. 2024. DOI: 10.1016/j.ejrad.2024.111392.

[96] SUN, YS; QU, YH; WANG, D et al.. **Deep learning model improves radiologists' performance in detection and classification of breast lesions**. CHINESE JOURNAL OF CANCER RESEARCH, dez. 2021. DOI: 10.21147/j.issn.1000-9604.2021.06.05.

[97] NICA, Raluca-Elena; ÈERBANESCU, Mircea-Sebastian; FLORESCU, Lucian-Mihai et al.. **Deep Learning: a Promising Method for Histological Class Prediction of Breast Tumors in Mammography**. J Digit Imaging, set. 2021. DOI: 10.1007/s10278-021-00508-4.

[98] PARK, Jun Hyeong; LIM, June Hyuck; KIM, Seonhwa et al.. **A Multi-label Artificial Intelligence Approach for Improving Breast Cancer Detection With Mammographic Image Analysis**. In Vivo, out. 2024. DOI: 10.21873/in vivo.13767.

[99] CHEN, Jian-Ling; CHENG, Lan-Hsin; WANG, Jane et al.. **A YOLO-based AI system for classifying calcifications on spot magnification mammograms**. Biomed Eng Online, maio 2023. DOI: 10.1186/s12938-023-01115-w.

[101] ELHAKIM, Mohammad Talal; STOUGAARD, Sarah Wordenskjold; GRAUMANN, Ole et al.. **Breast cancer detection accuracy of AI in an entire screening population: a retrospective, multicentre study**. Cancer Imaging, dez. 2023. DOI: 10.1186/s40644-023-00643-x.

[102] BAHL, M; DO, S. **Artificial Intelligence for Breast Cancer Screening: Tradeoffs between Sensitivity and Specificity**. RADIOLOGY-ARTIFICIAL INTELLIGENCE, maio 2024. DOI: 10.1148/ryai.240184.

[103] ZHANG, Haicheng; LIN, Fan; ZHENG, Tiantian et al.. **Artificial intelligence-based classification of breast lesion from contrast enhanced mammography: a**

multicenter study. Int J Surg, maio 2024. DOI: 10.1097/JS9.0000000000001076.

[104] TURK, F; AKKUR, E; EROGUL, O. **BI-RADS CATEGORIES AND BREAST LESIONS CLASSIFICATION OF MAMMOGRAPHIC IMAGES USING ARTIFICIAL INTELLIGENCE DIAGNOSTIC MODELS.** NEURAL NETWORK WORLD, 2023. DOI: 10.14311/NNW.2023.33.023.

[105] ELHAKIM, Mohammad T; STOUGAARD, Sarah W; GRAUMANN, Ole et al.. **AI-integrated Screening to Replace Double Reading of Mammograms: A Population-wide Accuracy and Feasibility Study.** Radiol Artif Intell, set. 2024. DOI: 10.1148/ryai.230529.

[106] SCHAFFTER, Thomas; BUIST, Diana S M; LEE, Christoph I et al.. **Evaluation of Combined Artificial Intelligence and Radiologist Assessment to Interpret Screening Mammograms.** JAMA Netw Open, mar. 2020. DOI: 10.1001/jamanetworkopen.2020.0265.

[107] WAN, Yun; TONG, Yunfei; LIU, Yuanyuan et al.. **Evaluation of the Combination of Artificial Intelligence and Radiologist Assessments to Interpret Malignant Architectural Distortion on Mammography.** Front Oncol, maio 2022. DOI: 10.3389/fonc.2022.880150.

[108] HSU, William; HIPPE, Daniel S; NAKHAEI, Noor et al.. **External Validation of an Ensemble Model for Automated Mammography Interpretation by Artificial Intelligence.** JAMA Netw Open, nov. 2022. DOI: 10.1001/jamanetworkopen.2022.42343.

[109] LEE, Jeong Hoon; KIM, Ki Hwan; LEE, Eun Hye et al.. **Improving the Performance of Radiologists Using Artificial Intelligence-Based Detection Support Software for Mammography: A Multi-Reader Study.** Korean J Radiol, abr. 2022. DOI: 10.3348/kjr.2021.0476.

[110] SECHOPOULOS, Ioannis; MANN, Ritse M. **Stand-alone artificial intelligence - The future of breast cancer screening?.** Breast, jan. 2020. DOI: 10.1016/j.breast.2019.12.014

[111] BADAWY, E; SHALABY, FS; SAIF-EL-NASR, SI et al.. **The synergy between AI and radiologist in advancing digital mammography: comparative study between stand-alone radiologist and concurrent use of artificial intelligence in BIRADS 4 and 5 female patients.** EGYPTIAN JOURNAL OF RADIOLOGY AND NUCLEAR MEDICINE, nov. 2023. DOI: 10.1186/s43055-023-01136-4.

[112] HEYWANG-KÖBRUNNER, Sylvia H; HACKER, Astrid; JÄNSCH, Alexander et al.. **Use of novel artificial intelligence computer-assisted detection (AI-CAD) for screening mammography: an analysis of 17,884 consecutive two-view full-field digital mammography screening exams.** Acta Radiol, ago. 2023. DOI: 10.1177/02841851231187382.

[113] KERSCHKE, Laura; WEIGEL, Stefanie; RODRIGUEZ-RUIZ, Alejandro et al.. **Using deep learning to assist readers during the arbitration process: a lesion-**

based retrospective evaluation of breast cancer screening performance. Eur Radiol, 2022. DOI: 10.1007/s00330-021-08217-w.

[114] SQUIRES, Steven; HARKNESS, Elaine F.; EVANS, D. Gareth; ASTLEY, Susan M. **The effect of variable labels on deep learning models trained to predict breast density.** Biomedical Physics & Engineering Express, v. 9, n. 3, p. 035030, Apr. 19, 2023. DOI: 10.1088/2057-1976/accae.

[115] GHOSH, A. **Artificial Intelligence Using Open Source BI-RADS Data Exemplifying Potential Future Use.** JOURNAL OF THE AMERICAN COLLEGE OF RADIOLOGY, jan. 2019. DOI: 10.1016/j.jacr.2018.09.040.

[116] TAO, XT; GANDOMKAR, Z; LI, T et al.. **Using Radiomics-Based Machine Learning to Create Targeted Test Sets to Improve Specific Mammography Reader Cohort Performance: A Feasibility Study.** JOURNAL OF PERSONALIZED MEDICINE, jun. 2023. DOI: 10.3390/jpm13060888.

[117] ZHANG, TY; TAN, T; SAMPERNA, R et al. **Radiomics and artificial intelligence in breast imaging: a survey.** ARTIFICIAL INTELLIGENCE REVIEW, out. 2023. DOI: 10.1007/s10462-023-10543-y

[118] ALSHAYEJI, MH; AL-BULOUSHI, J. **Breast Cancer Classification Using Concatenated Triple Convolutional Neural Networks Model.** BIG DATA AND COGNITIVE COMPUTING, set. 2023. DOI: 10.3390/bdcc7030142.

[119] SALAMA, WM; ELBAGOURY, AM; ALY, MH. **Novel breast cancer classification framework based on deep learning.** IET IMAGE PROCESSING, nov. 2020. DOI: 10.1049/iet-ipr.2020.0122.

[120] TLUSTY, T.; OZERY-FLATO, M.; BARROS, V.; BARKAN, E.; AMIT, M.; GRUEN, D.; GUINDY, M.; ARAZI, T.; ROZIN, M.; ROSEN-ZVI, M.; HEXTER, E. *Pre-biopsy Multi-class Classification of Breast Lesion Pathology in Mammograms.* In: **Lecture Notes in Computer Science**, Cham: Springer, 2021. p. 356–366. DOI: 10.1007/978-3-030-87589-3_29.

[121] BARROS, Vesna; TLUSTY, Tal; BARKAN, Ella et al.. **Virtual Biopsy by Using Artificial Intelligence-based Multimodal Modeling of Binational Mammography Data.** Radiology, 2023. DOI: 10.1148/radiol.220027.

BOBOWICZ, Maciej; RYGUSIK, Marlena; BULER, Jakub et al.. **Attention-Based Deep Learning System for Classification of Breast Lesions-Multimodal, Weakly Supervised Approach.** Cancers (Basel), jun. 2023. DOI: 10.3390/cancers15102704.

[122] SAJID, U; KHAN, RA; SHAH, SM et al.. **Breast cancer classification using deep learned features boosted with handcrafted features.** BIOMEDICAL SIGNAL PROCESSING AND CONTROL, set. 2023. DOI: 10.1016/j.bspc.2023.105353.

[123] HASSAN, Loay; ABD EL-NASSER, Mohamed; SALEH, Adel; PUIG, Domenec. **Breast tumor classification in digital tomosynthesis based on deep learning radiomics.** In: CORTÉS, A. et al. (Eds.). Artificial Intelligence Research and

Development. Tarragona: IOS Press, 2022. p. 269–278. DOI: 10.3233/FAIA220348. Disponível em: <https://ebooks.iospress.nl/doi/10.3233/FAIA220348>. Acesso em: 19 out. 2025.

[124] ALHUSSAN, AA; ABDELHAMID, AA; TOWFEK, SK et al.. **Classification of Breast Cancer Using Transfer Learning and Advanced AI-Biruni Earth Radius Optimization**. BIOMIMETICS, set. 2023. DOI: 10.3390/biomimetics8030270.

[125] LUO, Jun; AREFAN, Dooman; ZULEY, Margarita; SUMKIN, Jules; WU, Shandong. **Deep Curriculum Learning in Task Space for Multi-Class Based Mammography Diagnosis**. Pittsburgh: University of Pittsburgh, 2021. arXiv preprint arXiv:2110.11320. Disponível em: <https://arxiv.org/abs/2110.11320>. Acesso em: 19 out. 2025.

[126] SAMEE, NA; ATTEIA, G; MESHOUL, S et al.. **Deep Learning Cascaded Feature Selection Framework for Breast Cancer Classification: Hybrid CNN with Univariate-Based Approach**. MATHEMATICS, out. 2022. DOI: 10.3390/math10193631

[127] R, Kayalvizhi; H, Heartlin Maria; S, Malarvizhi et al.. **Hardware deployment of deep learning model for classification of breast carcinoma from digital mammogram images**. Med Biol Eng Comput, jul. 2023. DOI: 10.1007/s11517-023-02883-2.

[128] DARWEESH, MS; ADEL, M; ANWAR, A et al.. **Early breast cancer diagnostics based on hierarchical machine learning classification for mammography images**. COGENT ENGINEERING, jan. 2021. DOI: 10.1080/23311916.2021.1968324.

[129] CHEN, YH; LIU, YY; WANG, C et al.. **BRAIxDet: Learning to detect malignant breast lesion with incomplete annotations**. MEDICAL IMAGE ANALYSIS, ago. 2024. DOI: 10.1016/j.media.2024.103192.

[130] SAKTHIVEL, NK; SUBASREE, S; MALIK, S et al.. **A Wrapper based feature extraction framework based on AlexNet deep convolutional neural network parameters optimized using gradient-based optimizer for mammogram images**. CONCURRENCY AND COMPUTATION-PRACTICE & EXPERIENCE, ago. 2022. DOI: 10.1002/cpe.7008.

[131] MAMUN, Rafsan Al; RAFIN, Gazi Abu; ALAM, Adnan; SEFAT, Md Al Imran. Application of Deep Convolution Neural Network in Breast Cancer Prediction using Digital Mammograms. In: **INTERNATIONAL CONFERENCE ON INNOVATION IN INFORMATION SYSTEMS AND ENGINEERING COMPUTING (IISEC)**, 2021, Dhaka. *Anais...* [S.l.]: IEEE, 2021. DOI: 10.1109/IISEC54230.2021.9672368.

[132] KARTHIGA, R; NARASIMHAN, K; CHINTHAGINJALA, R et al.. **A novel exploratory hybrid deep neural network to predict breast cancer for mammography based on wavelet features**. MULTIMEDIA TOOLS AND APPLICATIONS, jan. 2024. DOI: 10.1007/s11042-023-18012-y.

[133] KHALID, A; MEHMOOD, A; ALABRAH, A et al. **Breast Cancer Detection and Prevention Using Machine Learning**. DIAGNOSTICS, out. 2023. DOI: 10.3390/diagnostics13193113.

[134] IBRAHIM, NM; ALI, B; AL JAWAD, F et al.. **Breast Cancer Detection in the Equivocal Mammograms by AMAN Method**. APPLIED SCIENCES-BASEL, jun. 2023. DOI: 10.3390/app13127183

[135] PATI, A; PARHI, M; PATTANAYAK, BK et al. **Breast Cancer Diagnosis Based on IoT and Deep Transfer Learning Enabled by Fog Computing**. DIAGNOSTICS, jul. 2023. DOI: 10.3390/diagnostics13132191.

[136] QIAN, LR; BAI, JX; HUANG, YQ et al.. **Breast cancer diagnosis using evolving deep convolutional neural network based on hybrid extreme learning machine technique and improved chimp optimization algorithm**. BIOMEDICAL SIGNAL PROCESSING AND CONTROL, jan. 2024. DOI: 10.1016/j.bspc.2023.105492.

[137] CHOUHAN, N; KHAN, A; SHAH, JZ et al.. **Deep convolutional neural network and emotional learning based breast cancer detection using digital mammography**. COMPUTERS IN BIOLOGY AND MEDICINE, maio 2021. DOI: 10.1016/j.compbimed.2021.104318.

[138] MANALI, D; DEMIREL, H; ELEYAN, A. **Deep Learning Based Breast Cancer Detection Using Decision Fusion**. COMPUTERS, nov. 2024. DOI: 10.3390/computers13110294

[139] TRANG, Nguyen Thi Hoang; LONG, Khuong Quynh; AN, Pham Le et al.. **Development of an Artificial Intelligence-Based Breast Cancer Detection Model by Combining Mammograms and Medical Health Records**. Diagnostics (Basel), fev. 2023. DOI: 10.3390/diagnostics13030346.

[140] KUMAR, MG; KOCHARLA, S; YASWANTH, N et al.. **EHA-LNN: Optimized light gradient-boosting machine enabled neural network for cancer detection using mammography**. BIOMEDICAL SIGNAL PROCESSING AND CONTROL, jul. 2025. DOI: 10.1016/j.bspc.2025.107540.

[141] KUMAR, PJS; SHIBU, S; MOHAN, M et al.. **Hybrid deep learning enabled breast cancer detection using mammogram images**. BIOMEDICAL SIGNAL PROCESSING AND CONTROL, set. 2024. DOI: 10.1016/j.bspc.2024.106310.

[150] NESS, Lior; BARKAN, Ella; OZERY-FLATO, Michal. Improving the performance and explainability of mammogram classifiers with local annotations. In: **Lecture Notes in Computer Science**. Cham: Springer, 2020. p. 41–52. DOI: https://doi.org/10.1007/978-3-030-61166-8_4.

[151] ELTRASS, AS; SALAMA, MS. **Fully automated scheme for computer-aided detection and breast cancer diagnosis using digitised mammograms**. IET IMAGE PROCESSING, fev. 2020. DOI: 10.1049/iet-ipr.2018.5953.

[152] RABIEI, Reza; AYYOUBZADEH, Seyed Mohammad; SOHRABEI, Solmaz et al.. **Prediction of Breast Cancer using Machine Learning Approaches**. J Biomed Phys Eng, jun. 2022. DOI: 10.31661/jbpe.v0i0.2109-1403.

[153] PERTUZ, Said; ORTEGA, David; SUAREZ, Érika et al.. **Saliency of breast lesions in breast cancer detection using artificial intelligence**. Sci Rep, nov. 2023. DOI: 10.1038/s41598-023-46921-3.

[154] CEREKCI, Esmâ; ALIS, Deniz; DENIZOGLU, Nurper et al.. **Quantitative evaluation of Saliency-Based Explainable artificial intelligence (XAI) methods in Deep Learning-Based mammogram analysis**. Eur J Radiol, fev. 2024. DOI: 10.1016/j.ejrad.2024.111356.

[155] LÂNG, Kristina; HOFVIND, Solveig; RODRÍGUEZ-RUIZ, Alejandro et al.. **Can artificial intelligence reduce the interval cancer rate in mammography screening?**. Eur Radiol, jan. 2021. DOI: 10.1007/s00330-021-07686-3.

[156] TZORTZIS, IN; DAVRADOU, A; RALLIS, I et al.. **Tensor-Based Learning for Detecting Abnormalities on Digital Mammograms**. DIAGNOSTICS, out. 2022. DOI: 10.3390/diagnostics12102389.

[157] LARSEN, Marthe; OLSTAD, Camilla F; LEE, Christoph I et al.. **Performance of an Artificial Intelligence System for Breast Cancer Detection on Screening Mammograms from BreastScreen Norway**. Radiol Artif Intell, abr. 2024. DOI: 10.1148/ryai.230375

[158] LEONG, YS; HASIKIN, K; LAI, KW et al. **Microcalcification Discrimination in Mammography Using Deep Convolutional Neural Network: Towards Rapid and Early Breast Cancer Diagnosis**. FRONTIERS IN PUBLIC HEALTH, abr. 2022. DOI: 10.3389/fpubh.2022.875305.

[159] HONJO, Takashi; UEDA, Daiju; KATAYAMA, Yutaka et al.. **Visual and quantitative evaluation of microcalcifications in mammograms with deep learning-based super-resolution**. Eur J Radiol, jul. 2022. DOI: 10.1016/j.ejrad.2022.110433.

[160] LIU, Yuanyuan; TONG, Yunfei; WAN, Yun et al.. **Identification and diagnosis of mammographic malignant architectural distortion using a deep learning based mask regional convolutional neural network**. Front Oncol, abr. 2023. DOI: 10.3389/fonc.2023.1119743.

[161] PESAPANE, Filippo; TRENTIN, Chiara; FERRARI, Federica et al.. **Deep learning performance for detection and classification of microcalcifications on mammography**. Eur Radiol Exp, nov. 2023. DOI: 10.1186/s41747-023-00384-3.

[162] FAVATI, B; BORGHERESI, R; GIANNELLI, M et al.. **Radiomic Applications on Digital Breast Tomosynthesis of BI-RADS Category 4 Calcifications Sent for Vacuum-Assisted Breast Biopsy**. DIAGNOSTICS, abr. 2022. DOI: 10.3390/diagnostics12040771.

[163] SHAO, Zhenzhen; CAI, Yuxin; HAO, Yajuan et al.. **AI-based strategies in breast mass ? 2 cm classification with mammography and tomosynthesis.** Breast, set. 2024. DOI: 10.1016/j.breast.2024.103805.

[164] QI, Longxiu; LU, Xing; SHEN, Hailin et al.. **Automatic Classification of Mass Shape and Margin on Mammography with Artificial Intelligence: Deep CNN Versus Radiomics.** J Digit Imaging, mar. 2023. DOI: 10.1007/s10278-023-00798-w

[165] PATRA, A; BEHERA, SK; SETHY, PK et al.. **Breast mass density categorisation using deep transferred EfficientNet with support vector machines.** MULTIMEDIA TOOLS AND APPLICATIONS, fev. 2024. DOI: 10.1007/s11042-024-18507-2.

[166] FU, XJ; CAO, H; HU, HX et al.. **Attention-Based Active Learning Framework for Segmentation of Breast Cancer in Mammograms.** APPLIED SCIENCES-BASEL, jan. 2023. DOI: 10.3390/app13020852.

[167] ZAHOOR, S; SHOAIB, U; LALI, IU. **Breast Masses Segmentation: A Framework of Skip Dilated Semantic Network and Machine Learning.** INTERNATIONAL JOURNAL ON ARTIFICIAL INTELLIGENCE TOOLS, maio 2023. DOI: 10.1142/S0218213023400122.

[168] LEE, RS; DUNNMON, JA; HE, A et al. **Comparison of segmentation-free and segmentation-dependent computer-aided diagnosis of breast masses on a public mammography dataset.** JOURNAL OF BIOMEDICAL INFORMATICS, jan. 2021. DOI: 10.1016/j.jbi.2020.103656.

[169] GNANASEKARAN, VS; JOYPAUL, S; SUNDARAM, PM et al.. **Deep learning algorithm for breast masses classification in mammograms.** IET IMAGE PROCESSING, out. 2020. DOI: 10.1049/iet-ipr.2020.0070

[170] ANAYA-ISAZA, A; MERA-JIMENEZ, L; CABRERA-CHAVARRO, JM et al.. **Comparison of Current Deep Convolutional Neural Networks for the Segmentation of Breast Masses in Mammograms.** IEEE ACCESS, 2021. DOI: 10.1109/ACCESS.2021.3127862.

[171] CHANG, K; BEERS, AL; BRINK, L et al.. **Multi-Institutional Assessment and Crowdsourcing Evaluation of Deep Learning for Automated Classification of Breast Density.** JOURNAL OF THE AMERICAN COLLEGE OF RADIOLOGY, dez. 2020. DOI: 10.1016/j.jacr.2020.05.015.

[172] RESCH, Daphne; LO GULLO, Roberto; TEUWEN, Jonas et al.. **AI-enhanced Mammography With Digital Breast Tomosynthesis for Breast Cancer Detection: Clinical Value and Comparison With Human Performance.** Radiol Imaging Cancer, jul. 2024. DOI: 10.1148/rycan.230149.

[173] HOU, R; LO, JY; MARKS, JR et al.. **Classification performance bias between training and test sets in a limited mammography dataset.** PLOS ONE, fev. 2024. DOI: 10.1371/journal.pone.0282402.

[174] MAO, N; SHI, YH; LIAN, C et al.. **Intratumoral and peritumoral radiomics for preoperative prediction of neoadjuvant chemotherapy effect in breast cancer based on contrast-enhanced spectral mammography.** EUROPEAN RADIOLOGY, maio 2022. DOI: 10.1007/s00330-021-08414-7.

[175] TALERO, Jesica L.; ESPINOSA, Ricardo A. **Comparison between HOG and Haar descriptors in the detection of abnormal tissue in mammograms.** Research on Biomedical Engineering, São Paulo, v. 35, n. 3, p. 225–236, 2019. DOI: 10.1007/s42600-019-00033-4

[178] KHAIRNAR, S; THEPADE, SD; GITE, S. **Effect of image binarization thresholds on breast cancer identification in mammography images using OTSU, Niblack, Burnsen, Thepade's SBTC.** INTELLIGENT SYSTEMS WITH APPLICATIONS, jul. 2021. DOI: 10.1016/j.iswa.2021.200046.

[179] ARUN KUMAR, S; SASIKALA, S. **Review on Deep Learning-Based CAD Systems for Breast Cancer Diagnosis.** Technol Cancer Res Treat, jun. 2023. DOI: 10.1177/15330338231177977

[180] BAHL, Manisha; KSHIRSAGAR, Ashwini; POHLMAN, Scott et al.. **Traditional versus modern approaches to screening mammography: a comparison of computer-assisted detection for synthetic 2D mammography versus an artificial intelligence algorithm for digital breast tomosynthesis.** Breast Cancer Res Treat, jan. 2025. DOI: 10.1007/s10549-024-07589-z.

[181] SKARPING, I; LARSSON, M; FÖRNVIK, D. **Analysis of mammograms using artificial intelligence to predict response to neoadjuvant chemotherapy in breast cancer patients: proof of concept.** Eur Radiol, 2022. DOI: 10.1007/s00330-021-08306-w.

[182] ROMANOV, Stepan; HOWELL, Sacha; HARKNESS, Elaine et al.. **Artificial Intelligence for Image-Based Breast Cancer Risk Prediction Using Attention.** Tomography, dez. 2023. DOI: 10.3390/tomography9060165.

[183] LI, H; ROBINSON, K; LAN, L et al.. **Temporal Machine Learning Analysis of Prior Mammograms for Breast Cancer Risk Prediction.** CANCERS, abr. 2023. DOI: 10.3390/cancers15072141.

[184] MENDES, João; OLIVEIRA, Bernardo; ARAÚJO, Carolina et al.. **You get the best of both worlds? Integrating deep learning and traditional machine learning for breast cancer risk prediction.** Comput Biol Med, fev. 2025. DOI: 10.1016/j.compbimed.2025.109733.

[185] DAMIANI, Celeste; KALLIATAKIS, Grigorios; SREENIVAS, Muthyala et al.. **Evaluation of an AI Model to Assess Future Breast Cancer Risk.** Radiology, jun. 2023. DOI: 10.1148/radiol.222679.

[186] OMOLEYE, OJ; WOODARD, AE; HOWARD, FM et al.. **External Evaluation of a Mammography-based Deep Learning Model for Predicting Breast Cancer in an Ethnically Diverse Population.** RADIOLOGY-ARTIFICIAL INTELLIGENCE,

nov. 2023. DOI: 10.1148/ryai.220299.

[187] GRIMM, LJ; PLICHTA, JK; HWANG, ES. **More Than Incremental: Harnessing Machine Learning to Predict Breast Cancer Risk.** JOURNAL OF CLINICAL ONCOLOGY, jun. 2022. DOI: 10.1200/JCO.21.02733.

[188] AVENDANO, Daly; MARINO, Maria Adele; BOSQUES-PALOMO, Beatriz A et al.. **Validation of the Mirai model for predicting breast cancer risk in Mexican women.** Insights Imaging, out. 2024. DOI: 10.1186/s13244-024-01808-3

[189] PAWAR, Shivaji D; SHARMA, Kamal K; SAPATE, Suhas G et al.. **Multichannel DenseNet Architecture for Classification of Mammographic Breast Density for Breast Cancer Detection.** Front Public Health, maio 2022. DOI: 10.3389/fpubh.2022.885212

[190] SHU, H; CHIANG, TY; WEI, P et al.. **A Deep Learning Approach to Re-create Raw Full-Field Digital Mammograms for Breast Density and Texture Analysis.** RADIOLOGY-ARTIFICIAL INTELLIGENCE, jul. 2021. DOI: 10.1148/ryai.2021200097.

[191] HAJI MAGHSOUDI, Omid; GASTOUNIOTI, Aimilia; SCOTT, Christopher et al.. **Deep-LIBRA: An artificial-intelligence method for robust quantification of breast density with independent validation in breast cancer risk assessment.** Med Image Anal, jul. 2021. DOI: 10.1016/j.media.2021.102138

[192] MAGNI, V; INTERLENGHI, M; COZZI, A et al.. **Development and Validation of an AI-driven Mammographic Breast Density Classification Tool Based on Radiologist Consensus.** RADIOLOGY-ARTIFICIAL INTELLIGENCE, mar. 2022. DOI: 10.1148/ryai.210199

[193] ELEZABY, Mai A. **Impact of a Deep Learning Model for Predicting Mammographic Breast Density in Routine Clinical Practice: A Methodologic Framework for Clinical Testing of Artificial Intelligence Tools.** J Am Coll Radiol, jun. 2022. DOI: 10.1016/j.jacr.2022.05.013.

[194] ANGELONE, F; PONSIGLIONE, AM; RICCIARDI, C et al.. **A Machine Learning Approach for Breast Cancer Risk Prediction in Digital Mammography.** APPLIED SCIENCES-BASEL, nov. 2024. DOI: 10.3390/app142210315.

[195] SQUIRES, Steven; HARKNESS, Elaine F.; MACKENZIE, Alistair et al.. **Breast density prediction from low and standard dose mammograms using deep learning: effect of image resolution and model training approach on prediction quality.** Biomedical physics & engineering express, maio 2024a. DOI: 10.1088/2057-1976/ad470b.

[196] SQUIRES, S; MACKENZIE, A; EVANS, DG et al.. **Capability and reliability of deep learning models to make density predictions on low-dose mammograms.** JOURNAL OF MEDICAL IMAGING, jul. 2024b. DOI: 10.1117/1.JMI.11.4.044506.

[197] CHEN, X; ZHANG, Y; ZHOU, JH et al.. **Diagnosis of architectural distortion**

on digital breast tomosynthesis using radiomics and deep learning.
FRONTIERS IN ONCOLOGY, dez. 2022. DOI: 10.3389/fonc.2022.991892

[198] CORTES-ROJAS, Fausto David; HERNÁNDEZ-RODRÍGUEZ, Yazmín Mariela; BAYAREH-MANCILLA, Rafael et al.. **An Artificial Intelligence-Based Tool for Enhancing Pectoral Muscle Segmentation in Mammograms: Addressing Class Imbalance and Validation Challenges in Automated Breast Cancer Diagnosis.** Diagnostics (Basel), out. 2024. DOI: 10.3390/diagnostics14192144.

[199] HONG, SP; BHATTACHARYYA, D. **A Study on the Improvement of Security Image Analysis Capability Using Artificial Intelligence.** TEHNICKI GLASNIK-TECHNICAL JOURNAL, dez. 2023. DOI: 10.31803/tg-20230121113550.

[200] FU, XJ; CAO, H; HU, HX et al.. **Attention-Based Active Learning Framework for Segmentation of Breast Cancer in Mammograms.** APPLIED SCIENCES-BASEL, jan. 2023. DOI: 10.3390/app13020852.

[201] GHANI, NASM; JUMAAT, AK; MAHMUD, R et al.. **Breast Abnormality Boundary Extraction in Mammography Image Using Variational Level Set and Self-Organizing Map (SOM).** MATHEMATICS, fev. 2023. DOI: 10.3390/math11040976.

[202] SABANI, Albin; LANDSMANN, Anna; HEJDUK, Patryk et al.. **BI-RADS-Based Classification of Mammographic Soft Tissue Opacities Using a Deep Convolutional Neural Network.** Diagnostics (Basel), jul. 2022. DOI: 10.3390/diagnostics12071564.

[203] YI, PH; LIN, A; WEI, JC et al.. **Deep-Learning-Based Semantic Labeling for 2D Mammography and Comparison of Complexity for Machine Learning Tasks.** JOURNAL OF DIGITAL IMAGING, ago. 2019. DOI: 10.1007/s10278-019-00244-w.

[204] CONDON, JJJ; TRINH, V; HALL, KA et al.. **Impact of Transfer Learning Using Local Data on Performance of a Deep Learning Model for Screening Mammography.** RADIOLOGY-ARTIFICIAL INTELLIGENCE, jul. 2024. DOI: 10.1148/ryai.230383.

[205] UNNISA, A. **A Validation Study Involving Development of Model by Application of Artificial Intelligence in Screening and Prognosis of Breast Cancer.** JOURNAL OF PHARMACEUTICAL NEGATIVE RESULTS, 2022. DOI: 10.47750/pnr.2022.13.S01.52.

[206] HEJDUK, Patryk; SEXAUER, Raphael; RUPPERT, Carlotta et al.. **Automatic and standardized quality assurance of digital mammography and tomosynthesis with deep convolutional neural networks.** Insights Imaging, maio 2023. DOI: 10.1186/s13244-023-01396-8.

[207] KHAN, AR; SABA, T; SADAD, T et al.. **Identification of Anomalies in Mammograms through Internet of Medical Things (IoMT) Diagnosis System.** COMPUTATIONAL INTELLIGENCE AND NEUROSCIENCE, set. 2022. DOI: 10.1155/2022/1100775.

[208] CHEN, PY; CHENG, YC; ZHONG, ZH et al.. **Information Security and Artificial Intelligence-Assisted Diagnosis in an Internet of Medical Thing System (IoMTS)**. IEEE ACCESS, 2024. DOI: 10.1109/ACCESS.2024.3351373.

[209] HASAN, Yumnah; DE LIMA, Allan; AMEREHI, Fatemeh; BULNES, Darian Reyes Fernández de; HEALY, Patrick; RYAN, Conor. Interpretable solutions for breast cancer diagnosis with grammatical evolution and data augmentation. In: SMITH, S.; et al. (ed.). Applications of Evolutionary Computation (EvoApplications 2024). Lecture Notes in Computer Science, v. 14634, p. 224–239. Cham: **Springer Nature Switzerland**, 2024. DOI: [10.1007/978-3-031-56852-7_15](https://doi.org/10.1007/978-3-031-56852-7_15)

[210] YALA, Adam; MIKHAEL, Peter G; LEHMAN, Constance et al.. **Optimizing risk-based breast cancer screening policies with reinforcement learning**. Nat Med, jan. 2022. DOI: 10.1038/s41591-021-01599-w.

[211] PETRILLO, A; FUSCO, R; DI BERNARDO, E et al.. **Prediction of Breast Cancer Histological Outcome by Radiomics and Artificial Intelligence Analysis in Contrast-Enhanced Mammography**. CANCERS, maio 2022. DOI: 10.3390/cancers14092132.

[212] NOMANI, A; ANSARI, Y; NASIRPOUR, MH et al.. **PSOWNNs-CNN: A Computational Radiology for Breast Cancer Diagnosis Improvement Based on Image Processing Using Machine Learning Methods**. COMPUTATIONAL INTELLIGENCE AND NEUROSCIENCE, maio 2022. DOI: 10.1155/2022/5667264.

[213] PFOB, A; LU, SC; SIDEY-GIBBONS, C. **Machine learning in medicine: a practical introduction to techniques for data pre-processing, hyperparameter tuning, and model comparison**. BMC MEDICAL RESEARCH METHODOLOGY, nov. 2022. DOI: 10.1186/s12874-022-01758-8.

[214] LEE, Si Eun; HONG, Hanpyo; KIM, Eun-Kyung. **Positive Predictive Values of Abnormality Scores From a Commercial Artificial Intelligence-Based Computer-Aided Diagnosis for Mammography**. Korean J Radiol, mar. 2024. DOI: 10.3348/kjr.2023.0907

ANEXO 1 - MANUSCRITO

Revisão integrativa sobre a usabilidade da IA em mamografia

Introdução: A alta taxa da incidência do câncer de mama é uma realidade mundial, o diagnóstico precoce é uma estratégia de saúde pública, realizada por meio da mamografia. A inteligência artificial (IA) tem se mostrado um bom aliado para auxiliar o médico radiologista a diagnosticar o câncer de mama, aumentando a precisão na detecção do câncer de mama e auxiliando os profissionais da saúde a identificar sinais de anormalidades de forma mais rápida e acurada, o que pode resultar em um diagnóstico mais precoce e, conseqüentemente, em tratamentos mais eficazes. **Objetivo:** Avaliar a produção científica sobre a utilização da inteligência artificial em mamografia, identificando tendências, lacunas de pesquisa e implicações para a prática radiológica. **Métodos:** Foi realizada uma revisão integrativa, utilizando os bancos de dados Pubmed, BVS e Web Of Science, com os descritores “artificial intelligence”, “machine learning”, “mammography”, foram incluídos artigos publicados nos últimos 5 anos, com o idioma em inglês, com o tema relacionado a inteligência artificial na mamografia ou tomossíntese, foram excluídos artigos que realizaram pesquisa com mamografia em conjunto com outros métodos por imagem e artigos de revisão de literatura. Foram selecionados 135 artigos **Resultados:** Os países com maior publicações foram Estados Unidos, Índia e Reino Unido. Já os fabricantes mais citados foram Hologic, GE e Siemens. Observou-se ainda que 111 trabalhos concentraram-se exclusivamente em mamografia digital, enquanto 15 combinaram mamografia e tomossíntese. Foram identificados 22 bancos de dados prontos disponíveis para criação de IA e 9 publicações tiveram objetivo de desenvolver um banco de dados. 19 estudos compararam o desempenho da IA com o médico radiologista na detecção e classificação de achados mamográficos através de métricas (AUC, acurácia, sensibilidade, especificidade, VPP e VPN). Foram mapeados as principais tendências de pesquisa no campo da IA em mamografia, classificando os estudos conforme o foco do desenvolvimento, a fim de identificar lacunas de conhecimento e recomendar futuras direções para pesquisas mais clinicamente relevantes, foram analisados 102 artigos identificando o tema central e suas métricas. Com o resultado desta dissertação, o produto tecnológico construído foi um material instrucional para desenvolver IA em mamografia **Conclusão:** A comparação entre IA e médicos radiologistas evidencia uma tendência de integração colaborativa, em que a IA atua como ferramenta de suporte clínico e segunda leitura, e não como substituta do profissional. Sobre os bancos de dados foi identificado avanços significativos na criação e utilização de bancos de dados para IA em mamografia, persistem limitações quanto à diversidade étnica, padronização e transparência metodológica. A predominância de bases de países desenvolvidos restringe a generalização dos algoritmos em contextos globais. Outro ponto relevante é que poucos estudos especificaram o uso de imagens com implantes mamários, baixa dose e mamografia com contraste, aspectos relevantes para a aplicabilidade clínica ampla.

Palavras-chaves: Inteligência artificial. Aprendizado de máquina. Mamografia.

ABSTRACT

Introduction: The high incidence rate of breast cancer is a global reality, and early diagnosis is a public health strategy carried out through mammography. Artificial intelligence (AI) has proven to be a valuable ally in assisting radiologists in diagnosing breast cancer, increasing the accuracy of breast cancer detection and helping healthcare professionals identify signs of abnormalities more quickly and accurately, which can result in earlier diagnosis and, consequently, more effective treatments.

Objective: To evaluate scientific production on the use of artificial intelligence in mammography, identifying trends, research gaps, and implications for radiological practice. **Methods:** An integrative review was conducted using the PubMed, BVS, and Web of Science databases, with the descriptors “artificial intelligence,” “machine learning,” and “mammography.” Articles published in the last five years in English on the topic of artificial intelligence in mammography or tomosynthesis were included. Articles that conducted research with mammography in conjunction with other imaging methods and literature review articles were excluded. A total of 135 articles were selected. **Results:** The countries with the most publications were the United States, India, and the United Kingdom. The most cited manufacturers were Hologic, GE, and Siemens. It was also observed that 111 studies focused exclusively on digital mammography, while 15 combined mammography and tomosynthesis. Twenty-two ready-made databases available for AI creation were identified, and nine publications aimed to develop a database. Nineteen studies compared the performance of AI with that of radiologists in the detection and classification of mammographic findings using metrics (AUC, accuracy, sensitivity, specificity, PPV, and NPV). The main research trends in the field of AI in mammography were mapped, classifying the studies according to their development focus in order to identify knowledge gaps and recommend future directions for more clinically relevant research. A total of 102 articles were analyzed, identifying the central theme and its metrics. As a result of this dissertation, the technological product developed was instructional material for developing AI in mammography. **Conclusion:** The comparison between AI and radiologists shows a trend toward collaborative integration, in which AI acts as a clinical support tool and second reader, rather than a substitute for professionals. Regarding databases, significant advances were identified in the creation and use of databases for AI in mammography, but limitations persist in terms of ethnic diversity, standardization, and methodological transparency. The predominance of databases from developed countries restricts the generalization of algorithms in global contexts. Another relevant point is that few studies have specified the use of images with breast implants, low dose, and contrast mammography, which are relevant aspects for broad clinical applicability.

Keywords: Artificial intelligence. Machine learning. Mammography

1. INTRODUÇÃO

Segundo a Organização Mundial da Saúde, o câncer de mama foi responsável por causar 685.000 mortes no mundo inteiro em 2020. (WHO, 2023). No Brasil, com exceção do câncer de pele não melanoma, o câncer de mama é o que mais causa morte entre as mulheres. As estratégias encontradas para aumentar a sobrevida é a detecção precoce, a mamografia é o único método que associada a programas de rastreamento, apresenta eficácia comprovada para a diminuição da mortalidade. (INCA, 2022).

A inteligência artificial (IA) tem se mostrado um bom aliado para auxiliar o médico radiologista a diagnosticar o câncer de mama. Segundo o documento “Considerações regulatórias sobre inteligência artificial para a saúde”, a IA é caracterizada como uma área da ciência da computação, estatística e engenharia que utiliza algoritmos ou modelos para realizar tarefas e mostrar comportamentos, como aprender, tomar decisões e fazer previsões. A IA possui subconjuntos, um dos principais é conhecido como Machine Learning (ML) ou Aprendizado de Máquina. Este permite que algoritmos de computador aprendam por meio de dados, sem a necessidade de programação explícita para desempenhar uma função específica. Com a crescente disponibilidade de dados sobre cuidados de saúde e o rápido progresso em técnicas analíticas, a IA apresenta um potencial significativo para revolucionar o setor da saúde, um dos pilares fundamentais para o bem-estar social e o desenvolvimento econômico global. (WHO, 2021)

Uma preocupação da OMS é que essas tecnologias de IA estão sendo implantadas muito rápido, em algumas vezes, sem uma compreensão completa de como podem funcionar, o que pode trazer benefícios ou malefícios aos usuários finais (WHO, 2023). Este estudo tem por objetivo avaliar a produção científica sobre a utilização da inteligência artificial em mamografia, identificando tendências, lacunas de pesquisa e implicações para a prática radiológica, através de uma Revisão Integrativa nas bases de dados Pubmed, Web Of Science e BVS, na utilização da IA para diagnosticar câncer de mama, identificando oportunidades para melhorias na precisão e confiabilidade do diagnóstico precoce.

2 METODOLOGIA

A presente pesquisa adota uma abordagem qualitativa, de natureza exploratória, com base em uma revisão integrativa da literatura, método amplamente reconhecido por permitir a síntese crítica de estudos primários, integrando diferentes abordagens metodológicas em um único corpo analítico (Whittemore; Knafl, 2005). No enfoque qualitativo de caráter exploratório, privilegia-se a abertura do delineamento, a sensibilidade ao contexto e a construção iterativa de significados a partir dos dados (Flick, 2009). Como também a integração de múltiplas fontes e estratégias analíticas funciona como triangulação, elevando a validade e a profundidade interpretativa das sínteses de literatura (Flick, 2013).

Para isso, foi realizada uma busca sistematizada nas bases de dados BVS, PubMed e Web of Science, utilizando os descritores booleanos “artificial intelligence” OR “machine learning” AND “mammography”, com recorte temporal dos últimos cinco anos, publicados em inglês. O processo de triagem seguiu critérios de inclusão e exclusão previamente definidos, conforme a Tabela 1.

Tabela 1: Critérios de inclusão e exclusão

Abordagem	Critérios de inclusão	Critérios de exclusão
Relevância do tema	Artigos que abordam a aplicação da IA em mamografia ou tomossíntese; banco de dados com mamografia e outros métodos por imagem	Artigos que não utilizassem IA em mamografia ou tomossíntese; artigos que desenvolveram ou compararam IA com outros métodos por imagem
Tipo de estudo	Artigos originais exploratório ou descritivo; Pesquisa Comparativa; Experimental, Pesquisa de Desenvolvimento; Pesquisa Aplicada;	Revisões sistemáticas, meta-análises e estudos de caso.
Idioma	Artigos publicados em Inglês	Todos idiomas que não foram publicados em inglês
Disponibilidade	Últimos 5 anos da publicação	Mais de 5 anos de publicação


Fonte: Da autora(2025)

Foram excluídos artigos que apresentavam IA de mamografia ou tomossíntese com outros métodos por imagem. Somente foi incluído outros métodos por imagem na categoria “Banco de dados” para poder identificar todas as bases de dados em

que os pesquisadores possam encontrar imagens prontas para aplicação de modelos de inteligência artificial em pesquisas futuras.

Os artigos foram organizados em uma planilha de Excel para facilitar a categorização e análise dos conteúdos selecionados, conforme propõem Botelho, Cunha e Macedo (2011) para pesquisas de natureza integrativa. Na primeira etapa, foram encontrados 193 artigos na base de dados BVS, 92 na PubMed e 257 na Web of Science, totalizando 542 artigos. Após a análise dos critérios de inclusão e exclusão, foram selecionados 135 artigos, os quais estão ilustrados na Figura 24, a qual apresenta tanto o número de artigos encontrados em cada base de dados quanto a quantidade de artigos incluídos na pesquisa.

Figura 1 - Processo de seleção de artigos




Fonte: Da autora (2025) Napkin

Após a seleção, os estudos foram classificados em três categorias temáticas principais: Banco de dados, Comparação entre IA e Radiologista e Inteligência Artificial, conforme o fluxograma da Figura 1. Essa etapa seguiu os princípios da análise categorial temática, conforme estabelecido por Bardin (2011), permitindo uma leitura aprofundada dos objetivos, métodos e contribuições de cada artigo. A categorização foi realizada com base nas técnicas de IA utilizadas, nos objetivos clínicos e nas métricas de avaliação quando disponibilizada pelos autores, favorecendo uma visão abrangente e crítica sobre o estado da arte. Deste modo, a revisão integrativa aqui empregada não se limita à simples descrição de evidências, mas busca interpretar e organizar os achados de modo a identificar lacunas,

tendências e implicações para futuras pesquisas e aplicações clínicas da IA em imagens médicas.

Figura 2: Fluxograma dos critérios de inclusão e exclusão




Fonte: Da autora (2025)

3. RESULTADOS

O primeiro resultado foi identificar as tendências de publicações através de um panorama geral das publicações dos últimos cinco anos que abordam IA em mamografia. A análise foi separada por ano de publicações; países que tiveram maior contribuições; quantidade de estudos que utilizaram mamografia e/ou tomossíntese e fabricantes mais citados, conforme a Figura 3.

Figura 3: Fluxograma metodologia panorama geral publicações



Fonte: Da autora (2025)

Os resultados do panorama geral de publicações foram analisados através do software RSTUDIO versão R 4.4.1 (2024-06-14 ucrt) através de gráficos e tabelas. O RStudio é um ambiente de desenvolvimento integrado voltado para a linguagem de programação R, amplamente utilizado por cientistas de dados e estatísticos. Ele oferece uma interface amigável e recursos avançados para análise de dados, visualização gráfica e criação de relatórios dinâmicos. (DATACAMP, 2025)

A análise do panorama global das publicações sobre o uso da IA em mamografia evidencia um crescimento expressivo da produção científica nos últimos cinco anos, com destaque para os anos de 2023 e 2024. Observa-se que a maior parte das pesquisas é proveniente de países com infraestrutura tecnológica avançada, especialmente Estados Unidos, Índia, Reino Unido e China, que concentram a maioria dos bancos de dados utilizados para treinamento e validação de algoritmos. A concentração geográfica, embora tenha impulsionado o desenvolvimento técnico, revela uma desigualdade científica que limita a generalização e a equidade diagnóstica dos modelos, sobretudo quando aplicados em populações sub-representadas de contextos latino-americanos e africanos (Yala et al. 2022, Mcdermott et al. 2023).

Do ponto de vista técnico, nota-se uma predominância de estudos voltados à mamografia digital (111 publicações), em detrimento de modalidades mais recentes, como a tomossíntese, identificada em apenas cinco pesquisas exclusivas. Embora a tomossíntese ofereça vantagens na detecção de lesões sobrepostas, sua aplicação

na modelagem de IA ainda é incipiente, o que indica um campo promissor a ser explorado. Da mesma forma, os fabricantes mais recorrentes - Hologic, GE e Siemens, demonstram a forte dependência tecnológica das pesquisas em poucos equipamentos, o que reforça o risco de viés de dispositivo e limita a robustez dos algoritmos em ambientes clínicos diversificados. Assim, evidencia-se a necessidade de ampliar a representatividade de fabricantes e promover estudos comparativos que analisem o impacto das variações de hardware e software no desempenho diagnóstico dos modelos.

3.1 Analisando os Banco de dados para construção de IA em mamografia

A categoria “Banco de dados”, teve por objetivo verificar os principais bancos de dados disponíveis para criação de IA. O método utilizado foi a revisão integrativa dos 135 estudos, identificando 22 citações de banco de dados prontos e 9 artigos que tiveram por objetivo desenvolver um banco de dados em mamografia.

Os pontos observados dos bancos de dados prontos foram: país, quantidade de imagens, quantidade de vezes em que o banco de dados foi citado em outros artigos, característica do banco de dados. Na caracterização do banco de dados foi analisada a quantidade de imagens, a modalidade de imagem (mamografia e/ou tomossíntese), o período da coleta de imagens, quantidade de centros de coleta, os modelos de IA utilizados e seus objetivos.

Os resultados encontrados dos bancos de dados prontos, em relação a quantidade de imagens, mostraram que o banco Optiman apresentou o maior volume de imagens, totalizando cerca de 7 milhões, enquanto o mini-MIAS, com 322 imagens, constitui o menor conjunto identificado. Em termos de produção de bancos de dados voltados à mamografia, os países com maior representatividade foram o Reino Unido e os Estados Unidos, cada um responsável pela criação de cinco bancos de dados distintos.

Os principais bancos de dados em mamografia reconhecidos ou utilizados em estudos submetidos à FDA, ou seja, considerados adequados para validação de algoritmos clínicos foram: Digital Database for Screening Mammography (DDSM), Curated Breast Imaging Subset of DDSM (CBIS-DDSM), INbreast Dataset, OPTIMAM Mammography Image Database (OMI-DB), Mammographic Image

Analysis Society (MIAS). Os dispositivos comerciais aprovados pela FDA como o ProFound AI – iCAD, Lunit INSIGHT MMG, Transpara e Therapixel MammoScreen, utilizaram bancos clínicos privados com milhões de exames anonimizados, validados segundo protocolos éticos revisados pela FDA e pelo *Institutional Review Board (IRB)*. Esses bancos são confidenciais, mas citam frequentemente DDSM, CBIS-DDSM e OMI-DB como datasets suplementares de treinamento ou calibração externa. (FDA, 2022)

Os resultados dos nove artigos que desenvolveram o banco de dados, destaca-se o estudo desenvolvido na Austrália por Frazer et al. (2023), como o maior número de imagens, um total de 4 milhões. Contudo, a ausência de informações sobre o número de centros de coleta limita a avaliação da diversidade tecnológica e demográfica do conjunto, comprometendo a análise da heterogeneidade de origem das imagens. Em seguida, o banco criado por Jeong et al. (2023) nos Estados Unidos reúne cerca de 3,65 milhões de imagens obtidas em quatro centros de coleta, o que favorece uma maior variação de equipamentos e protocolos de aquisição, fator essencial para o desenvolvimento de algoritmos mais generalizáveis e robustos diante de diferentes condições clínicas e técnicas.

Nos estudos de menor escala, observa-se um cenário contrastante. O banco de dados brasileiro elaborado por Monteiro Cordeiro et al. (2024), com 941 imagens provenientes de um único centro, reflete os desafios de infraestrutura e a limitação de diversidade tecnológica, o que pode reduzir a representatividade e aumentar o risco de overfitting quando os modelos são aplicados em outros contextos. Já o estudo conduzido por Khaled et al. (2022), no Egito, embora tenha incluído apenas 2.006 imagens de um centro de coleta, apresenta um diferencial relevante, o foco em mamografia com contraste, essa característica confere grande valor científico ao banco, uma vez que os modelos de IA desenvolvidos para mamografias com contraste diferem substancialmente daqueles aplicados a imagens convencionais, tanto na estrutura de dados quanto nas variáveis radiômicas utilizadas. Assim, a existência de um banco específico para mamografia com contraste representa um avanço estratégico na diversificação dos datasets disponíveis e contribui para o aprimoramento de algoritmos voltados a técnicas de diagnóstico mais sensíveis e dinâmicas.

Ao se considerar tanto os bancos de dados já existentes quanto aqueles desenvolvidos especificamente para as pesquisas, observa-se a incorporação de

uma diversidade razoável de origens étnicas. Contudo, verifica-se uma sub-representação significativa de mulheres afrodescendentes e asiáticas, o que constitui uma limitação relevante para a validação e a generalização dos modelos de IA aplicados à mamografia, uma vez que a ausência de diversidade demográfica compromete o desempenho equitativo dos algoritmos e a confiabilidade dos resultados obtidos (Mendes et al., 2022; Lee; Yala; Barzilay, 2021)

Sobre os modelos de IA utilizados nos estudos analisados, diversos modelos de IA foram empregados para o desenvolvimento, aprimoramento ou validação de bancos de dados de mamografia. Esses modelos apresentam abordagens distintas, desde redes neurais convolucionais (CNNs) até arquiteturas generativas adversariais (GANs) e métodos de explicabilidade, refletindo o avanço e a diversidade de técnicas aplicadas à área da detecção precoce do câncer de mama.

A família EfficientNet, proposta por Tan e Le (2019), representa uma das arquiteturas de CNN mais eficientes para análise de imagens médicas, pois equilibra profundidade, largura e resolução da rede por meio de um método de escalonamento composto. Essa abordagem permite alto desempenho com menor custo computacional, sendo amplamente utilizada em tarefas de classificação de imagens mamográficas e detecção de anomalias. O modelo EfficientNetB0, de menor porte, é ideal para bancos com número limitado de imagens; enquanto o EfficientNetB7 é uma versão mais profunda, com maior capacidade de generalização (Tan; Le, 2019).

O método Grad-CAM (Gradient-weighted Class Activation Mapping) é uma técnica de explicabilidade que permite visualizar quais regiões da imagem influenciaram a decisão de uma rede neural. No contexto da mamografia, o Grad-CAM é empregado para gerar mapas de calor que evidenciam áreas suspeitas, facilitando a validação clínica dos modelos e aumentando a transparência da IA (Selvaraju et al., 2017).

As GANs (Generative Adversarial Networks), propostas por Goodfellow et al. (2014), são redes compostas por dois modelos em competição, um gerador e um discriminador, capazes de criar imagens sintéticas realistas. Na mamografia, são utilizadas para aumentar o tamanho dos bancos de dados, corrigir desequilíbrios de classes e gerar variações anatômicas simuladas, essenciais para reduzir overfitting e ampliar a robustez dos algoritmos.

As variações como DCGAN e WGAN-GP aprimoram a estabilidade do treinamento; CycleGAN e Pix2Pix são usadas para tradução de imagem para

imagem, como simular diferentes modalidades (ex.: mamografia com e sem contraste), e C-DCGAN permite controle condicional sobre as imagens geradas (Goodfellow et al., 2014; Isola et al., 2017; Gulrajani et al., 2017).

O modelo EfficientDet-B0 é uma variação orientada à detecção de objetos derivada da EfficientNet, incorporando uma rede de fusão ponderada de características (BiFPN), o que otimiza a identificação de lesões e microcalcificações em mamografias (Tan; Le, 2020). Já a VGG11, proposta por Simonyan e Zisserman (2015), é uma rede clássica que, com a adição de “batch normalization”, aumenta a estabilidade do treinamento e reduz o risco de sobreajuste, sendo útil em bancos com variação limitada de imagens.

O modelo Character-level BERT, derivado da arquitetura “Bidirectional Encoder Representations from Transformers”, é aplicado para o processamento de textos associados aos metadados dos bancos (como relatórios, descrições clínicas e anotações). Sua função é analisar e padronizar informações não estruturadas, o que contribui para a integridade semântica dos bancos de dados e para o aprendizado multimodal entre imagem e texto (Devlin et al., 2019).

A diversidade de modelos identificados demonstra um ecossistema de IA em rápida evolução. Contudo, observa-se que muitos bancos de dados ainda são desenvolvidos sem integração explícita de modelos de aprendizado profundo, como verificado nos trabalhos de Frazer et al. (2023), Dahlblom et al. (2023), Aqdar et al. (2024) e Monteiro Cordeiro et al. (2024), o que revela uma lacuna metodológica na interoperabilidade entre bancos de dados e algoritmos. Essa ausência reforça a necessidade de padrões técnicos abertos e datasets multi-institucionais, garantindo maior diversidade e generalização dos modelos de IA aplicados à mamografia (Mcdermott et al., 2023).

3.2 Prática clínica do uso da IA em mamografia como suporte de diagnóstico

A categoria teve por objetivo comparar o desempenho diagnóstico da IA com o do radiologista na detecção e classificação de achados mamográficos, visando avaliar a potencialidade da IA como ferramenta de suporte clínico. O método utilizado foi através da revisão integrativa da literatura, com leitura dos resumos e métodos de 135 artigos para identificar estudos que compararam o desempenho da IA com o de radiologistas. Foram selecionados 19 artigos com esse objetivo e apresentavam

métricas diagnósticas, como AUC, acurácia, sensibilidade, especificidade, VPP e VPN, além da análise qualitativa da participação dos radiologistas nos experimentos. Nem todos artigos citaram todas as métricas, o que limita a análise de eficiência da comparação entre IA e Radiologista.

Os resultados encontrados destacam-se o estudo de Chen et al., (2023) e Wan, et al., (2022) pois foram os únicos que avaliaram todas as métricas. As métricas da IA no estudo de Chen et al., (2023) foram um pouco maiores que as dos Radiologistas. Na pesquisa de Wan et al., (2022), as melhores métricas foram do Radiologista com auxílio da IA.

No estudo de Badawy et al. (2023), foi utilizado o modelo comercial Lunit INSIGHT MMG, a pesquisa demonstrou que a inteligência artificial (IA) foi mais precisa do que os radiologistas na detecção de lesões malignas em mamografias digitais BIRADS 4 e 5. A IA obteve uma acurácia de 90,30%, superando os 82,84% alcançados pelos radiologistas. Embora os radiologistas apresentassem uma sensibilidade de 100%, a IA se destacou com um valor preditivo positivo significativamente maior (94,55% contra 82,84% dos radiologistas). No entanto, a sensibilidade do radiologista foi superior. A análise histopatológica foi utilizada como padrão de referência, e os resultados sugerem que a IA pode ser um aliado valioso para os radiologistas, proporcionando maior precisão na triagem de lesões malignas, mas sem substituir completamente o julgamento clínico humano.

Na pesquisa de Kerschke et al., (2022), a aplicação da IA modelo Transpara, reduziu significativamente a proporção de mulheres com falsos positivos, de 89,9% para 62,0%, enquanto aumentou a taxa de exames sem falsos positivos de 11,1% para 38,0%. Em termos de sensibilidade, houve uma pequena queda de 96,7% para 91,1%, indicando que algumas lesões malignas deixaram de ser identificadas pelo sistema. A análise específica de massas mostrou que a IA apresentou sensibilidade comparável à dos radiologistas, com uma redução substancial de falsos positivos. O valor preditivo positivo aumentou de 12,8% para 16,5%, sugerindo que a IA pode otimizar a eficiência do rastreamento.

O estudo de Tao et al., (2023) avaliou métricas somente da IA e teve por objetivo criar conjuntos de testes personalizados com o objetivo de melhorar o desempenho de grupos específicos de leitores de mamografias. Foram analisados 60 casos mamográficos de alta densidade, interpretados por 36 radiologistas divididos em dois grupos distintos. Os resultados demonstraram que a abordagem proposta foi

capaz de prever erros falso-positivos e falso-negativos, mas apresentou limitações na detecção de erros de localização.

Sobre a participação dos Radiologistas foi identificado a maior participação no estudo de Sechopoulos, Ioannis, Ritse (2020), totalizando 101 participantes, seguido de Elhakim (2023) com 22 radiologistas e Park et al (2024) com 15 radiologistas. A participação dos radiologistas nos estudos que comparam o desempenho diagnóstico entre IA e especialistas humanos é um fator determinante para a robustez metodológica e a validade dos resultados obtidos.

Apesar dos avanços observados, persistem lacunas estruturais e metodológicas que limitam a plena integração da IA à prática clínica. A ausência de padronização na avaliação das métricas, a variabilidade dos rótulos utilizados para o treinamento dos modelos, como evidenciado por Squires et al. (2023) e a escassez de bancos de dados multi-institucionais e multiétnicos ainda comprometem a generalização e a validação externa dos algoritmos. Estudos como o de Tao et al. (2023) apontam também a necessidade de desenvolver modelos adaptativos voltados ao aprimoramento do desempenho de radiologistas em diferentes níveis de experiência, sugerindo um movimento emergente em direção à IA educacional e personalizada. Assim, as próximas direções de pesquisa devem concentrar-se na criação de *datasets* diversificados, com no uso de métricas harmonizadas e na implementação de frameworks híbridos que combinem inteligência computacional e cognição humana, favorecendo uma leitura mamográfica mais precisa, inclusiva e contextualizada.


3.3. Identificando as tendências na criação de IA em mamografia

A categoria “Inteligência artificial” teve por objetivo mapear as principais tendências de pesquisa no campo da IA em mamografia, classificando os estudos conforme o foco do desenvolvimento, a fim de identificar lacunas de conhecimento e recomendar futuras direções para pesquisas mais clinicamente relevantes. A metodologia realizada através da revisão integrativa, abordou os 135 artigos científicos sobre IA aplicada à mamografia, publicados entre janeiro de 2019 à janeiro de 2025. A análise contemplou a leitura dos resumos, métodos, resultados e conclusões, classificando os estudos conforme o foco de desenvolvimento (classificação, detecção, predição de risco, avaliação de densidade, segmentação e

distorção arquitetural). Também foram identificados o país de origem, número de imagens utilizadas, centros de coleta, modelos de IA empregados e as métricas diagnósticas reportadas (AUC, acurácia, sensibilidade, especificidade, VPP e VPN). demonstradas.

Os objetivos e a quantidade de artigos encontrados estão descritos na Figura 4.

Figura 4: Objetivos da IA em Mamografia



Fonte: Da autora (2025)

A análise das diferentes categorias artigos evidenciou que a produção científica sobre IA em mamografia apresenta um avanço significativo em termos de diversidade temática e metodológica, refletindo a consolidação desse campo como uma das áreas mais dinâmicas da radiologia moderna. Os estudos analisados revelam predominância nas linhas de pesquisa voltadas à detecção e classificação do câncer de mama, com destaque para modelos baseados em DL e redes neurais convolucionais (CNNs), que atingiram métricas expressivas de desempenho. Pesquisas como as de McKinney et al. (2020) e Wan et al. (2022) demonstram que algoritmos bem treinados podem alcançar acurácia e AUC comparáveis ou superiores à leitura humana, consolidando a IA como ferramenta de apoio diagnóstico complementar ao radiologista.

Os avanços técnicos mais consistentes foram observados em modelos híbridos e em abordagens que utilizam aprendizado por transferência e aumento de dados para superar a escassez de amostras rotuladas. Estudos como o de Salama et al. (2020) e Alhussan et al. (2023) ilustram esse progresso, alcançando métricas acima de 98% de AUC e acurácia, ao empregar arquiteturas como ResNet50 combinadas com SVM e otimizadores baseados em algoritmos evolucionários. Esse cenário evidencia a maturidade metodológica do campo e a tendência de convergência entre precisão diagnóstica e aplicabilidade clínica. Contudo, a ausência de padronização na apresentação das métricas, principalmente VPP, VPN, sensibilidade e especificidade, ainda limita a comparação direta entre modelos e dificulta sua validação em contextos reais de rastreamento mamográfico (Mcdermott et al., 2023).

Nas categorias de microcalcificações e massas mamárias, verificou-se menor volume de publicações, mas alta qualidade metodológica. Os estudos de Leong et al. (2022) e Pesapane et al. (2023) obtiveram AUC acima de 97%, demonstrando a relevância do pré-processamento, da segmentação precisa e da escolha adequada da arquitetura neural. No entanto, observou-se carência de padronização em relação às projeções utilizadas (CC e MLO) e ao formato das imagens (DICOM ou JPEG), o que compromete a reprodutibilidade dos resultados e a extrapolação dos achados para cenários clínicos mais complexos. Essa limitação reforça a necessidade de protocolos unificados e de bancos de dados abertos multicêntricos, que contemplem maior diversidade de equipamentos, parâmetros técnicos e perfis demográficos (Frazer et al., 2023).

As áreas menos recorrentes, como detecção de distorção arquitetural e segmentação aplicada à construção de IAs, representam importantes lacunas de pesquisa. Apenas dois artigos foram encontrados com foco em distorção arquitetural, ambos desenvolvidos na China, utilizando abordagens distintas como radiômica e deep learning, com resultados promissores, mas ainda limitados (Liu et al., 2023; Chen et al., 2022). Da mesma forma, os estudos que exploram a segmentação, fundamental para delimitar regiões anatômicas e treinar modelos explicáveis, permanecem restritos e pontuais. Tal cenário demonstra que, embora o campo da IA em mamografia tenha avançado em desempenho, ainda carece de maior ênfase na interpretabilidade e explicabilidade dos algoritmos, aspectos fundamentais para a aceitação clínica e ética desses sistemas (WORLD HEALTH ORGANIZATION, 2023).

Outra limitação identificada refere-se à representatividade demográfica e geográfica dos bancos de dados utilizados. A maioria das pesquisas foi conduzida com imagens provenientes da América do Norte e Europa, resultando em modelos potencialmente enviesados e pouco generalizáveis. A sub-representação de populações latino-americanas, africanas e asiáticas compromete a equidade algorítmica e pode impactar o desempenho dos sistemas em populações diversas (Sechopoulos; Mann, 2020). Outro ponto relevante é que poucos estudos especificaram o uso de imagens com implantes mamários ou de baixa dose, aspectos relevantes para a aplicabilidade clínica ampla. Essa homogeneidade de dados representa uma das principais barreiras à generalização e validação externa dos modelos de IA.

Em síntese, o panorama atual indica um movimento de consolidação das pesquisas sobre IA em mamografia, com foco crescente na integração de sistemas híbridos, modelos preditivos e ferramentas explicáveis. As tendências mais recorrentes apontam para a busca de acurácia elevada aliada à eficiência operacional, enquanto as lacunas evidenciam a sugestões de colaborações multicêntricas, validações externas padronizadas e construção de datasets multiétnicos. A próxima geração de algoritmos deve priorizar não apenas o desempenho técnico, mas também a transparência, reprodutibilidade e ética no uso da IA. Assim, o futuro do rastreamento mamográfico com IA dependerá da capacidade da comunidade científica de equilibrar inovação tecnológica e equidade diagnóstica, garantindo avanços sustentáveis e aplicáveis à prática radiológica global (Mcdermott et al., 2023; WHO, 2023).

4. CONCLUSÃO

A análise abrangente da produção científica internacional sobre o uso da IA em mamografia revela uma expansão significativa das publicações nos últimos cinco anos, com maior concentração nos anos de 2023 e 2024. Esse crescimento é impulsionado, sobretudo, por países com elevada infraestrutura tecnológica, como Estados Unidos, Índia, Reino Unido e China, que concentram a maioria dos bancos de dados empregados no treinamento e validação dos algoritmos. Essa centralização geográfica, embora tenha promovido avanços técnicos notáveis, reforça uma

assimetria científica que limita a generalização e a equidade diagnóstica dos modelos, especialmente em populações sub-representadas de regiões latino-americanas e africanas (Yala et al. 2022; McDermott et al. 2023).

A análise dos bancos de dados disponíveis indica uma diversidade étnica apenas moderada, com evidente sub-representação de mulheres afrodescendentes e asiáticas. Essa limitação compromete a validação e a generalização dos modelos de IA, restringindo sua aplicabilidade em contextos clínicos plurais. Entre os conjuntos de dados amplamente reconhecidos e aceitos pela Food and Drug Administration (FDA) destacam-se o DDSM, o CBIS-DDSM, o INbreast, o OPTIMAM e o MIAS, que figuram entre os mais utilizados na construção e validação de algoritmos. Recomenda-se, contudo, a ampliação da abrangência desses bancos, incluindo mamografias com contraste e imagens de pacientes com implantes mamários, uma vez que tais características influenciam a leitura automatizada e permanecem pouco representadas na literatura analisada.

Em relação ao desempenho comparativo entre IA e radiologistas, constatou-se que os resultados mais promissores decorrem de abordagens colaborativas, nas quais a IA atua como ferramenta de apoio à decisão e não como substituta do profissional. Essa complementaridade reflete uma mudança paradigmática, posicionando a IA como uma “segunda leitura” ou sistema de triagem inteligente capaz de aprimorar a sensibilidade e a especificidade diagnóstica, reduzindo simultaneamente as taxas de falsos positivos. Contudo, a limitação no número de radiologistas avaliadores constitui um fator metodológico relevante, pois impacta diretamente a acurácia das métricas e restringe a aplicabilidade dos algoritmos em cenários clínicos heterogêneos.

As tendências identificadas na literatura indicam predomínio de pesquisas voltadas à detecção e classificação do câncer de mama, com ênfase em modelos de DL e redes neurais convolucionais (CNNs), que alcançaram métricas expressivas de desempenho. Os avanços mais consistentes foram observados em modelos híbridos e abordagens que empregam aprendizado por transferência e técnicas de aumento de dados para mitigar a escassez de amostras rotuladas. Entretanto, a ausência de padronização na apresentação das métricas, especialmente valor VPP, VPN, sensibilidade e especificidade, limita a comparabilidade entre estudos e dificulta a translação dos resultados para contextos clínicos reais. Por fim, verificou-se menor número de publicações em áreas como microcalcificações, massas mamárias,

detecção de distorção arquitetural, mamografia com contraste, implantes mamários e mamografia de baixa dose. Embora menos recorrentes, tais temas apresentam alta relevância metodológica e representam lacunas significativas para futuras investigações. A homogeneidade dos dados e a baixa representatividade de determinados subgrupos clínicos e demográficos configuram-se, portanto, como os principais obstáculos à generalização e à validação externa dos modelos de IA em mamografia.

Resumidamente é possível identificar que o primeiro objetivo, de identificar as principais limitações das tecnologias de IA na detecção precoce do câncer de mama, foi atingido ao evidenciar-se que a homogeneidade dos bancos de dados e a sub-representação étnica constituem barreiras à generalização dos modelos. O segundo objetivo, de comparar o desempenho diagnóstico da IA e dos radiologistas, demonstrou que abordagens colaborativas, nas quais a IA atua como suporte à decisão, obtêm melhor desempenho e maior confiabilidade clínica. O terceiro objetivo, voltado ao mapeamento das tendências de pesquisa, revelou o predomínio de estudos com modelos baseados em CNNs e DL, além do avanço de técnicas híbridas e de transferência de aprendizado como soluções para a limitação de amostras rotuladas e os principais objetivos em detectar e classificar o câncer de mama. Por fim, o quarto objetivo, de identificar os principais bancos de dados utilizados, foi alcançado mediante a caracterização dos datasets mais citados (DDSM, CBIS-DDSM, INbreast, OPTIMAM e MIAS) e pela constatação da necessidade de ampliação da diversidade demográfica e técnica, incluindo mamografias com contraste e com implantes mamários.

5 REFERÊNCIAS

ALHUSSAN, A. A.; ABDELHAMID, A. A.; TOWFEK, S. K. et al. Classification of breast cancer using transfer learning and advanced AI-Biruni Earth Radius Optimization. **Biomimetics**, set. 2023. DOI: 10.3390/biomimetics8030270.

AQDAR, K. B.; MUSTAFA, R. K.; ABDULQADIR, Z. H. et al. Mammogram mastery: a robust dataset for breast cancer detection and medical education. **Data in Brief**, ago. 2024. DOI: 10.1016/j.dib.2024.110633.

BADAWY, E.; SHALABY, F. S.; SAIF-EL-NASR, S. I. et al. The synergy between AI and radiologist in advancing digital mammography: comparative study between stand-alone radiologist and concurrent use of artificial intelligence in BIRADS 4 and 5 female patients. **Egyptian Journal of Radiology and Nuclear Medicine**, nov. 2023. DOI: 10.1186/s43055-023-01136-4.

BARDIN, L. **Análise de conteúdo**. Tradução: Luís Antero Reto; Augusto Pinheiro. São Paulo: Edições 70, 2011.

BOTELHO, L. L.; CUNHA, C. C.; MACEDO, M. C. O método da revisão integrativa nos estudos organizacionais. **Revista Eletrônica Gestão & Sociedade**, v. 5, n. 11, p. 121–136, 2011.

BRASIL. Ministério da Saúde. Instituto Nacional de Câncer José Alencar Gomes da Silva (INCA). **Deteção precoce do câncer de mama**. Rio de Janeiro: INCA, 2022. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-cancer-de-mama/acoes/deteccao-precoce>.

CHEN, J.-L.; CHENG, L.-H.; WANG, J. et al. A YOLO-based AI system for classifying calcifications on spot magnification mammograms. **Biomedical Engineering Online**, maio 2023. DOI: 10.1186/s12938-023-01115-w.

CHEN, X.; ZHANG, Y.; ZHOU, J.-H. et al. Diagnosis of architectural distortion on digital breast tomosynthesis using radiomics and deep learning. **Frontiers in Oncology**, dez. 2022. DOI: 10.3389/fonc.2022.991892.

DAHLBLOM, V.; DUSTLER, M.; BOLEJKO, A. et al. Malmö Breast Imaging Database: objectives and development. **Journal of Medical Imaging**, nov. 2023. DOI: 10.1117/1.JMI.10.6.061402.

DATA CAMP. **Tutorial do RStudio para iniciantes: um guia completo**. Disponível em: <https://www.datacamp.com/pt/tutorial/r-studio-tutorial>. Acesso em: 9 out. 2025.

DEVLIN, J. et al. **BERT: Pre-training of deep bidirectional transformers for language understanding**. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics (NAACL)*, p. 4171–4186, 2019.

FLICK, U. **Desenho da pesquisa qualitativa**. Porto Alegre: Artmed, 2013.

FLICK, U. **Introdução à pesquisa qualitativa**. 3. ed. Porto Alegre: Artmed, 2009.

FRAZER, H. M. L.; TANG, J. S. N.; ELLIOTT, M. S. et al. ADMANI: annotated digital mammograms and associated non-image datasets. **Radiology: Artificial Intelligence**, mar. 2023. DOI: 10.1148/ryai.220072.

GOODFELLOW, I. J. et al. **Generative adversarial nets**. *Advances in Neural Information Processing Systems (NeurIPS 2014)*, Montreal, Canada: Curran Associates, 2014. p. 2672–2680.

GULRAJANI, I. et al. **Improved training of Wasserstein GANs**. *Advances in Neural Information Processing Systems (NeurIPS 2017)*, Long Beach, CA: Curran Associates, 2017. p. 5767–5777.

ISOLA, P.; ZHU, J.-Y.; ZHOU, T.; EFROS, A. A. **Image-to-image translation with conditional adversarial networks**. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017)*, Honolulu, HI: IEEE, 2017. p. 5967–5976.

JEONG, J. J.; VEY, B. L.; BHIMIREDDY, A. et al. The EMory BrEast Imaging Dataset (EMBED): a racially diverse, granular dataset of 3.4 million screening and diagnostic mammographic images. **Radiology: Artificial Intelligence**, jan. 2023. DOI: 10.1148/ryai.220047.

KERSCHKE, L.; WEIGEL, S.; RODRIGUEZ-RUIZ, A. et al. Using deep learning to assist readers during the arbitration process: a lesion-based retrospective evaluation of breast cancer screening performance. **European Radiology**, 2022. DOI: 10.1007/s00330-021-08217-w.

KHALED, R.; HELAL, M.; ALFARGHALY, O. et al. Categorized contrast enhanced mammography dataset for diagnostic and artificial intelligence research. **Scientific Data**, mar. 2022. DOI: 10.1038/s41597-022-01238-0.

LEE, C. I.; YALA, A.; BARZILAY, R. Representation of patient diversity in artificial intelligence models for breast cancer screening. **Radiology: Artificial Intelligence**, v. 3, n. 4, p. e210006, 2021. DOI: 10.1148/ryai.2021210006.

LEONG, Y. S.; HASIKIN, K.; LAI, K. W. et al. Microcalcification discrimination in mammography using deep convolutional neural network: towards rapid and early breast cancer diagnosis. **Frontiers in Public Health**, abr. 2022. DOI: 10.3389/fpubh.2022.875305.

LIU, Y.; TONG, Y.; WAN, Y. et al. Identification and diagnosis of mammographic malignant architectural distortion using a deep learning-based mask regional convolutional neural network. **Frontiers in Oncology**, abr. 2023. DOI: 10.3389/fonc.2023.1119743.

MCDERMOTT, M. B. A. et al. Reproducibility in machine learning for health research: still a challenge despite progress. **Nature Medicine**, v. 29, p. 149–160, 2023.

MENDES, J. R.; SILVA, L. P.; FERREIRA, T. C. Artificial intelligence in breast imaging: challenges of dataset diversity and equity in algorithmic performance. **Journal of Digital Imaging**, v. 35, n. 4, p. 812–825, 2022. DOI: 10.1007/s10278-022-00635-1.

MONTEIRO CORDEIRO, N.; FACINA, G.; PINTO NAZÁRIO, A. C. et al. Towards precision medicine in breast imaging: a novel open mammography database with tailor-made 3D image retrieval for AI and teaching. **Computer Methods and Programs in Biomedicine**, mar. 2024. DOI: 10.1016/j.cmpb.2024.108117.

PESAPANE, F.; TRENTIN, C.; FERRARI, F. et al. Deep learning performance for detection and classification of microcalcifications on mammography. **European Radiology Experimental**, nov. 2023. DOI: 10.1186/s41747-023-00384-3.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2025. Disponível em: <https://www.r-project.org/>. Acesso em: 19 out. 2025.

RSTUDIO TEAM. **RStudio: integrated development environment for R**. Boston: Posit Software, PBC, 2023. Disponível em: <https://posit.co/>. Acesso em: 19 out. 2025.

SALAMA, W. M.; ELBAGOURY, A. M.; ALY, M. H. Novel breast cancer classification framework based on deep learning. **IET Image Processing**, nov. 2020. DOI: 10.1049/iet-ipr.2020.0122.

SECHOPOULOS, I.; MANN, R. M. Stand-alone artificial intelligence: the future of breast cancer screening? **The Breast**, jan. 2020. DOI: 10.1016/j.breast.2019.12.014.

SELVARAJU, R. R. et al. **Grad-CAM: visual explanations from deep networks via gradient-based localization**. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Venice, p. 618–626, 2017. DOI: 10.1109/ICCV.2017.74.

SIMONYAN, K.; ZISSERMAN, A. **Very deep convolutional networks for large-scale image recognition**. *International Conference on Learning Representations (ICLR)*, 2015. Disponível em: <https://arxiv.org/abs/1409.1556>. Acesso em: 19 out. 2025.

SQUIRES, S.; HARKNESS, E. F.; EVANS, D. G.; ASTLEY, S. M. The effect of variable labels on deep learning models trained to predict breast density. **Biomedical Physics & Engineering Express**, v. 9, n. 3, p. 035030, 2023. DOI: 10.1088/2057-1976/accae.

TAN, M.; LE, Q. V. **EfficientNet: rethinking model scaling for convolutional neural networks**. *Proceedings of the 36th International Conference on Machine Learning (ICML)*, Long Beach, CA: PMLR, 2019. p. 6105–6114. Disponível em: <https://arxiv.org/abs/1905.11946>. Acesso em: 19 out. 2025.

UNITED STATES. Food and Drug Administration (FDA). **Artificial Intelligence/Machine Learning (AI/ML)-Based Software as a Medical Device (SaMD) Action Plan**. Silver Spring, MD: Center for Devices and Radiological Health, 2022. Disponível em: <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-software-medical-device>. Acesso em: 18 out. 2025.

WAN, Y.; TONG, Y.; LIU, Y. et al. Evaluation of the combination of artificial intelligence and radiologist assessments to interpret malignant architectural distortion on mammography. **Frontiers in Oncology**, maio 2022. DOI: 10.3389/fonc.2022.880150.

WHITTEMORE, R.; KNAFL, K. The integrative review: updated methodology. **Journal of Advanced Nursing**, v. 52, n. 5, p. 546–553, 2005. DOI: 10.1111/j.1365-2648.2005.03621.x.

WORLD HEALTH ORGANIZATION (WHO). **Artificial Intelligence in Health: ethics and governance of artificial intelligence for health**. Geneva: WHO, 2023.


WORLD HEALTH ORGANIZATION (WHO). **Ethics and governance of artificial intelligence for health**. Geneva: World Health Organization, 2021. Disponível em: <https://www.who.int/publications/i/item/9789240029208>. Acesso em: 18 out. 2025.

YALA, A. et al. Toward fairness in artificial intelligence for mammography screening: challenges and future directions. **Nature Medicine**, v. 28, p. 2437–2448, 2022.

ANEXO 2 - PRODUTO TECNOLÓGICO

Essa dissertação tem como produto tecnológico a descrição de um material instrucional para desenvolver IA para mamografia. Na Figura 1 é apresentado o Fluxograma dos processos.

Figura 1: Fluxograma desenvolvimento IA em Mamografia



Fonte: Da autora (2025) com apoio IA Napkin

Para a sua construção, siga os dez passos do fluxograma:

1- Escolha de banco de dados

Escolha mais de um banco de dados descritos na Tabela 1

Tabela 1 - Banco de dados

Nome	Link de acesso
Digital Database for Screening Mammography (DDSM),	www.eng.usf.edu ou DDSM Mammography
Curated Breast Imaging Subset of DDSM (CBIS-DDSM),	CBIS-DDSM - The Cancer Imaging Archive (TCIA)
OPTIMAM Mammography Image Database	OMI-DB
Mammographic Image Analysis Society (MIAS).	Mammographic Image Analysis Society (MIAS) database v1.21 ou MIAS Mammography
Mammogram Mastery: A Robust Dataset for Breast Cancer Detection and Medical Education	https://data.mendeley.com/datasets/fvjhtskg93/1
The EMory BrEast imaging Dataset (EMBED):	EMory BrEast Imaging Dataset (EMBED) -

	Registry of Open Data on AWS
Categorized contrast enhanced mammography dataset for diagnostic and artificial intelligence research	https://github.com/omar-mohamed/CDD-CESM-Dataset

Fonte: Da autora (2025)

2 - Definição do Problema

O primeiro passo é definir o objetivo do algoritmo, por exemplo, classificação de imagens entre benignas e malignas, detecção de nódulos ou microcalcificações, ou segmentação de áreas suspeitas. O objetivo precisa ser alinhado às métricas de desempenho desejadas, como precisão, sensibilidade e especificidade (Litjens et al., 2017).

3- Preparação dos Dados

- Anotação: Certifique-se de que as imagens tenham rótulos claros como normal, presença de nódulos, microcalcificações ou de acordo com o seu objetivo.
- Pré-processamento: Aplique técnicas de normalização para padronizar os níveis de cinza e use métodos para remoção de ruídos e aumento do contraste, garantindo que as imagens estejam uniformes para o modelo (Gonzalez; Woods, 2008).

4- Divisão do Conjunto de Dados

Dividir os dados em três partes:

- Treinamento: 70% das imagens para treinar o modelo.
- Validação: 15% para ajustar os hiperparâmetros.
- Teste: 15% para avaliar o desempenho final do algoritmo.

5- Escolha da Arquitetura do Modelo

- Utilize técnicas híbridas com algoritmos de DL, como Redes Neurais Convolucionais (CNNs), que são projetadas para análise de imagens e combine com Redes Neurais Recorrentes (RNNs), ou com técnicas de acordo com o seu objetivo.
- Escolha arquiteturas robustas, como ResNet, DenseNet ou EfficientNet, amplamente utilizadas em imagens médicas devido à sua eficiência na

extração de características, utilizados para a classificação do câncer de mama (Shen et al., 2017).

6- Construção do Modelo

- Configure camadas convolucionais para extrair características como texturas e bordas. As camadas convolucionais são responsáveis por identificar e extrair automaticamente padrões relevantes de uma imagem mamográfica, como bordas, texturas e formas que podem indicar lesões suspeitas. Essa etapa ocorre nas camadas intermediárias de uma rede neural convolucional (CNN). A camada de entrada recebe a imagem em formato numérico (matriz de pixels normalizados), as camadas convolucionais aplicam filtros que percorrem a imagem para detectar detalhes locais e, por fim, a camada de saída transforma essas informações em uma previsão, por exemplo, a probabilidade de presença de anomalias. Em síntese, a rede aprende progressivamente a reconhecer características visuais complexas, partindo de padrões simples (bordas e texturas) até formas clínicas mais abstratas, permitindo que a IA auxilie na análise diagnóstica de mamografias.
- Adicione camadas de *pooling*. Essa camada é aplicada depois das camadas convolucionais, e têm a função de reduzir o tamanho dos dados (ou seja, a dimensionalidade) sem perder as informações mais importantes. Elas resumem os mapas de características extraídos anteriormente, mantendo apenas os padrões mais relevantes, como as regiões que indicam bordas ou texturas significativas. Por exemplo, se uma imagem de entrada tem 128 x 128 pixels e passa por uma camada de max pooling 2 x 2, ela é reduzida para 64 x 64, conservando as informações principais, mas com menos dados a processar. Em seguida, nas camadas totalmente conectadas, a rede reúne todas essas informações resumidas para realizar a classificação final, decidindo, por exemplo, se a imagem apresenta uma área suspeita ou não..
- Defina a função de perda, como *binary cross-entropy* para problemas binários, e escolha um otimizador, como Adam, para o ajuste dos pesos (Litjens et al, 2017). Por exemplo, a função de perda mede o quão errado o modelo está em suas previsões. Para problemas binários (como “câncer” vs “sem câncer”), usamos a binary cross-entropy, que compara a probabilidade prevista com o rótulo verdadeiro (0 ou 1). Se o modelo prevê 0.9 para um caso positivo (rótulo

1), a perda será pequena. Se prevê 0.1 para o mesmo caso, a perda será grande. Isso força o modelo a ajustar seus pesos para melhorar as previsões. O otimizador ADAM é o algoritmo que ajusta os pesos da rede neural para minimizar a função de perda.

7- Treinamento do Modelo

- Treine o modelo usando o conjunto de treinamento.
- Monitore métricas como precisão e perda no conjunto de validação para identificar possíveis problemas de *overfitting* ou *underfitting*. *Overfitting* significa que o modelo aprende demais os dados de treino, até os ruídos e detalhes irrelevantes, funciona muito bem no treino, mas falha em novos dados. Já no *Underfitting* o modelo não aprende o suficiente, nem os padrões principais dos dados. Tem desempenho ruim tanto no treino quanto no teste.
- Aprimoramento do Modelo. Avalie os erros, identifique onde o modelo errou, quais tipos de lesões ele confunde e se há padrões de erros.
- Aplique *data augmentation* para aumentar a variabilidade dos dados, incluindo operações como rotação, espelhamento e alteração de brilho. *Data augmentation* (aumento de dados) consiste em criar versões modificadas das imagens originais para aumentar a diversidade do conjunto de treinamento sem coletar novas imagens. Isso evita o *overfitting*, pois o modelo não memoriza os dados, aprende padrões mais gerais. Simula variações reais: como mudanças de posição, iluminação ou ruído, como também aumenta a robustez: melhora o desempenho em imagens de diferentes equipamentos ou pacientes
- Ajuste hiperparâmetros, como a taxa de aprendizado e o número de camadas, para melhorar o desempenho do modelo.

8- Avaliação do Modelo

- Teste o modelo com o conjunto de testes para verificar seu desempenho final.
- Use métricas como a AUC, acurácia, sensibilidade, especificidade, VPP e VPN.
- Por fim, valide com a maior quantidade de Médicos Radiologistas possíveis.

9- Implementação e Integração

- Desenvolva uma interface WEB, se possível, para que médicos e profissionais de saúde utilizem o modelo de forma prática.

10- Validação Clínica e Ética

- Utilize o aplicativo em situações e ambientes reais, realizando testes em condições clínicas para garantir que o modelo é eficaz e confiável.
- Certifique-se de cumprir as regulamentações éticas relacionadas ao uso de dados médicos e privacidade dos pacientes, conforme o documento da WHO, “Ética e governança da inteligência artificial para a saúde” disponível em: <https://www.who.int/publications/i/item/9789240029200>