



**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS VII - GOVERNADOR ANTÔNIO MARIZ
CENTRO DE CIÊNCIAS EXATAS E SOCIAIS APLICADAS
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

FELIPE MEDÉIA BENTO

**Redes Neurais Convolucionais aplicadas na análise de imagens
médicas: Um mapeamento de casos de câncer de mama**

**Patos, PB
2025**

FELIPE MEDÉIA BENTO

**Redes Neurais Convolucionais aplicadas na análise de imagens
médicas: Um mapeamento de casos de câncer de mama**

Trabalho de Conclusão do Curso II
apresentado à coordenação do curso de
Bacharelado em Computação do Centro
de Ciências Exatas e Sociais Aplicadas da
Universidade Estadual da Paraíba, em
cumprimento às exigências legais para a
obtenção do título de Graduado no Curso
de Bacharelado em Ciências da
Computação.

Área de concentração: Inteligência
artificial .

Orientador(a): Prof^a Dra. Jannayna Domingues Barros Filgueira

Patos, PB
2025

É expressamente proibida a comercialização deste documento, tanto em versão impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que, na reprodução, figure a identificação do autor, título, instituição e ano do trabalho.

B478r Bento, Felipe Medéia.

Redes neurais convolucionais aplicadas na análise de imagens médicas [manuscrito] : um mapeamento de casos de câncer de mama / Felipe Medéia Bento. - 2025.

66 f. : il. color.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Ciência da computação) - Universidade Estadual da Paraíba, Centro de Ciências Exatas e Sociais Aplicadas, 2025.

"Orientação : Prof. Dra. Jannayna Domingues Barros Filgueira, Coordenação do Curso de Computação - CCEA".

1. Redes neurais. 2. Inteligência artificial. 3. Câncer de mama. 4. Mamografia. I. Título

21. ed. CDD 006.42

A minha mãe, Roseli Silva Bento, exemplo e modelo para a vida.

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela força e coragem me concedida para nunca desistir apesar das dificuldades e do caminho tortuoso até o fim dessa experiência acadêmica.

Agradeço à minha orientadora, Dra. Jannayna Domingues por dedicação, perseverança e empenho em meu auxílio sou ainda mais grato por ela não ter desistido mesmo com muitas orientações.

Agradeço a minha família, meu pai Egnomar Medeia e meus irmãos, Érike Medeia e Eryka Maria Medeia e em especial minha mãe Roseli Bento que sempre me incentivou a continuar e buscar conquistas.

Agradeço também aos amigos e familiares que sempre me apoiaram e direta ou indiretamente me ajudaram a chegar a esse momento e a cada professor por quem passei nesse trajeto, agradeço pelos ensinamentos para o curso e para a vida.

Quero agradecer também aos professores que se fizeram presentes na banca para essa conclusão.

Quero agradecer a cada um que participou dessa enorme jornada até aqui e me fizeram ser essa pessoa que está dando mais um passo rumo ao futuro com tantos aprendizados, o futuro que é o agora.

Consagre ao Senhor todos os seus sonhos e tudo o que você for fazer. E
você será bem sucedido em todos eles.

Provérbios 16:3

Resumo

O câncer de mama é uma realidade para muitos brasileiros atingindo em média mais de 70 mil pessoas anualmente desde 2022. Apesar de ser uma doença mais comum em mulheres, uma pequena parcela de homens também podem apresentá-la. Dado isso, o foco deste estudo é investigar como uso de redes neurais convolucionais (CNNs) para análise de imagens de mamografia, visando avaliar sua eficiência como ferramenta auxiliar no diagnóstico precoce em consideração a todos os métodos e processos necessários para determinar a existência da doença, pode reduzir o tempo necessário para um diagnóstico quando usados pelos médicos em suas análises, e com isso aumentar as chances de tratamentos menos rigorosos e invasivos. Empregando dois modelos de redes neurais nesse trabalho: o *AlexNet*, um modelo de análise de imagens mais antigo, porém robusto, e o *ResNet*, com uma arquitetura de camadas mais performática. Para ambos foi usado o mesmo dataset, onde as imagens foram trabalhadas para se adequarem a cada modelo, para o *AlexNet* foi um pouco diferente na parte de sua montagem, por ser mais antigo cada camada precisou ser definida diferente do *ResNet* que possui um modelo pré-treinado que é o *ResNet50*, deixando assim mais simples sua implementação e complexo o seu processamento. Com os primeiros resultados apenas alguns ajustes foram feitos, assim pôde ser analisado todo o processamento e retorno de cada conjunto para os parâmetros submetidos, tais como o número de épocas, padrões de normalização, conjunto de treino e teste, controle de *overfitting*, tudo para garantir que os modelos fossem treinados da melhor e mais eficiente forma possível. A partir disso os resultados de alguns atingiram em média valores de 86% e 87% de acurácia para o *AlexNet* e *ResNet50* respectivamente se mostrando modelos eficientes para a análise e identificação dos casos para as mamografias com um bom nível de retorno para o objetivo proposto.

Palavras-Chaves: Inteligência Artificial; Câncer de mama; Redes neurais convolucionais.

Abstract

Breast cancer is a reality for many Brazilians, affecting on average more than 70,000 people annually since 2022. Although it is a disease more common in women, a small percentage of men can also be affected. Given this, the focus of this study is to investigate how the use of convolutional neural networks (CNNs) for the analysis of mammography images can evaluate their efficiency as an auxiliary tool for early diagnosis. Considering all the necessary methods and processes to determine the presence of the disease, CNNs can reduce the time required for diagnosis when used by doctors in their analyses, thereby increasing the chances of less aggressive and invasive treatments. This study employs two neural network models: AlexNet, an older yet robust image analysis model, and ResNet, which features a more performant layered architecture. The same dataset was used for both, with images preprocessed to suit each model. For AlexNet, the setup was slightly different due to its older architecture, requiring each layer to be defined manually. In contrast, ResNet uses a pre-trained model (ResNet50), making implementation simpler but its processing more complex. With the initial results, only a few adjustments were necessary, allowing for a comprehensive analysis of the processing and output of each model given the submitted parameters such as the number of epochs, normalization patterns, training and testing sets, overfitting control ensuring the models were trained as effectively and efficiently as possible. As a result, the models achieved average accuracy rates of approximately 86% for AlexNet and 87% for ResNet50, demonstrating their efficiency in analyzing and identifying cases in mammography images, with a solid performance for the proposed objective.

Keywords: Artificial Intelligence; Breast Cancer; Convolutional Neural Networks.

LISTA DE ILUSTRAÇÕES

Figura 1 – Estágios de desenvolvimento do câncer.....	19
Figura 2 – Autoexame das Mamas.....	21
Figura 3 – Arquitetura da AlexNet.....	33
Figura 4 – Modelo de bloco ResNet.....	34
Figura 5 – Arquitetura YOLO.....	35
Figura 6 - Exemplo de mamografia da classe negativa (sem anomalia).....	38
Figura 7 - Exemplo de mamografia da classe positiva (com anomalia).....	38

LISTA DE GRÁFICOS

Gráfico 1 – Taxas de mortalidade por câncer de mama, ajustadas por idade pela população mundial, por 100 mil mulheres. Brasil e Regiões, 2000 a 2021.....	26
Gráfico 2 – Mortalidade proporcional por câncer de mama segundo faixa etária, Brasil 2000 a 2021.....	27
Gráfico 3 - Métricas de desempenho do AlexNet.....	49
Gráfico 4 - Métricas de desempenho do AlexNet quando foram rodadas 18 épocas de 50..	50
Gráfico 5 - Métricas de desempenho do ResNet.....	51

LISTA DE QUADROS

Quadro 1 – Classificação BI-RADS.....	23
Quadro 2 - Rótulos da presença de câncer.....	40
Quadro 3 - Rótulos de multi classes.....	40

LISTA DE TABELAS

Tabela 1 - Métricas de desempenho do modelo AlexNet entre as épocas 12 a 18.....	42
Tabela 2 - Métricas de desempenho do modelo ResNet entre as épocas 11 a 15.....	43
Tabela 3 - Estrutura das camadas do AlexNet.....	46
Tabela 4 - Estrutura das camadas do ResNet.....	47
Tabela 5 - Matriz de confusão do AlexNet.....	48
Tabela 6 - Matriz de confusão do AlexNet quando foram rodadas 18 épocas de 50.....	49
Tabela 7 - Matriz de confusão do ResNet.....	51

LISTA DE ABREVIATURAS E SIGLAS

CM	Câncer De Mama
CNN	Redes Neurais Conclucionais
<i>DL</i>	<i>Deep Learning</i>
IA	Inteligência Artificial
INCA	Instituto Nacional do Câncer
DNN	<i>Deep Neural Network</i>
<i>ReLu</i>	<i>Rectified Linear Unit</i>
YOLO	<i>You only look once</i>
ML	<i>Machine Learning</i>
MMG	<i>Mamografia</i>
ACR	<i>American College of Radiology</i>
BI-RADS	<i>Breast Imaging Reporting and Data System</i>

SUMÁRIO

1 INTRODUÇÃO.....	13
1.1 Objetivos.....	13
1.2 Problemática.....	14
1.3 Justificativa.....	14
1.4 Trabalhos relacionados.....	15
1.5 Resumo da metodologia.....	16
1.6 Organização e estrutura do trabalho.....	16
2 REFERENCIAL TEÓRICO.....	18
2.1 Câncer de mama.....	18
2.1.1 Fatores de risco.....	19
2.1.2 Métodos de diagnóstico.....	20
2.1.3 Métodos para tratamento.....	24
2.1.4 Índices de casos e mortalidade de câncer de mama no Brasil.....	25
2.2 Conceitos fundamentais de Inteligência Artificial (IA).....	28
2.2.1 Aplicação da Inteligência Artificial na área médica.....	30
2.2.2 Inteligência Artificial aplicada ao diagnóstico e tratamento do câncer.....	31
2.3 Algoritmos de classificação de imagens cancerígenas.....	32
2.3.1 Principais algoritmos aplicados ao diagnóstico precoce do câncer de mama...	32
3 METODOLOGIA.....	36
3.1 Métodos para seleção de atributos e classificação.....	36
3.2 Base de dados.....	36
3.3 Pré-processamento dos dados.....	39
3.4 Redes neurais aplicadas ao processo de classificação.....	40
3.4.1 Processo de treinamento e validação.....	41
3.4.2 Métricas de avaliação.....	44
4 RESULTADOS E DISCUSSÕES.....	45
5 CONSIDERAÇÕES FINAIS.....	52
REFERÊNCIA.....	54
APÊNDICE.....	57

1 INTRODUÇÃO

O câncer de mama é um grande vilão que tem se mostrado presente na vida de muitas mulheres e em alguns casos atingindo até homens, mudando suas vidas e rotinas podendo levar até a morte. Segundo o Observatório APS (2024), o câncer de mama é o tipo mais incidente no Brasil e no mundo, com exceção do câncer de pele não melanoma. Em 2022, foi a causa de 77.014 internações em todos os municípios do Brasil. Então, o que vem a ser o câncer de mama ou neoplasia e como ele ocorre?

Ainda segundo a mesma fonte, a neoplasia de mama é caracterizada pela multiplicação desordenada de células anormais no seio, formando um tumor maligno. Este tipo de câncer é mais comum em mulheres, em casos raros, homens podem desenvolver, chegando a 1% do total de casos .

Com base nos dados do Instituto Nacional do Câncer (INCA), em 2024 o câncer de mama tem tudo para continuar sendo o mais incidente nas mulheres, como citado anteriormente, estimando um total de 73.610 casos (INCA, 2024a).

Diante dessa realidade alarmante, torna-se essencial buscar alternativas tecnológicas que colaborem com o diagnóstico precoce da doença, aumentando as chances de um tratamento eficaz e menos invasivo. Nesse contexto, esta pesquisa explora o uso de modelos de Redes Neurais Convolucionais (CNNs), uma vertente da inteligência artificial voltada à análise de imagens, para facilitar e agilizar a interpretação de exames de mamografia. A proposta é avaliar a eficiência dessas redes como ferramenta de apoio ao diagnóstico, utilizando arquiteturas distintas como o *AlexNet*, um modelo clássico e robusto, e o *ResNet50*, uma estrutura moderna com desempenho mais eficiente.

1.1 Objetivos

Assim, o presente trabalho tem como objetivo geral aplicar Redes Neurais Convolucionais (CNNs) em imagens médicas de mamografia a fim de demonstrar sua eficiência para auxiliar no diagnóstico precoce do câncer de mama. Para isto, apresentam-se os seguintes objetivos específicos (OE):

OE1: Selecionar e estudar CNNs para uso com imagens de mamografia;

OE2: Selecionar dataset para a aplicação;

OE3: Desenvolver algoritmo para aplicar às imagens de câncer de mama obtidas em banco de dados;

OE4: Realizar testes para classificação e validação do método desenvolvido;

OE5: Obter compreensões relevantes sobre os testes realizados.

1.2 Problemática

O câncer de mama é uma das maiores causas de mortes entre mulheres e em 2024 tem tudo para continuar sendo o mais incidente, estimando um total de 73.610 casos segundo o (INCA, 2024a). O câncer de mama apresenta um crescimento rápido, em alguns casos, e desordenado de células deformadas, com isso formará um tumor ou nódulo em uma das mamas ou na axila, mudança no aspecto da pele e produção de secreção sanguinolenta ou serosa pelos mamilos também são algumas das características (MACHADO, 2024).

Conhecendo a complexidade e fragilidade por trás da análise das mamografias, onde muitas vezes são necessários mais de um parecer médico, mas que ainda assim é uma das formas mais utilizadas e aceitas para a detecção do câncer de mama, e de todos os passos necessários para levar ao diagnóstico mais preciso, a presente proposta visa apresentar uma ferramenta de auxílio para superar essa problemática, com o auxílio de um modelo de Redes Neurais Convolucionais (CNN), analisar as imagens de mamografias, treinar e obter resultados consolidados, buscando auxiliar no diagnóstico mais preciso e rápido.

1.3 Justificativa

O rastro que o câncer de mama vem deixando na história é gigantesco visto os números que foram apontados pelo Instituto Nacional do Câncer (INCA) e suas estimativas futuras também trazem um grande alarde sobre esse assunto, então mesmo conhecendo as formas de combate, o que estaria sendo a trava para a não diminuição desses casos? Quais as dificuldades encontradas ou não, que prejudicam essas estimativas? É isso que as Redes Neurais Conclucionais (CNNs) aplicadas na análise de imagens médicas de mamografias vai buscar resolver.

Nessa busca pela melhor forma, por mais eficiência, precisão e agilidade, a Inteligência Artificial (IA) tem se mostrado uma forte aliada quando o assunto é análise de imagens e grandes quantidades de dados dentre muitas outras áreas de

destaque. Com a grande e crescente capacidade dos modelos de *Machine Learning* e ainda mais tendo em vista as variações e peculiaridades dos casos, o uso de um sistema que tenha autonomia para aprender e reconhecer padrões torna-se essencial.

Ao fazer uso dessas tecnologias para análise das imagens resultantes dos exames como, mamografias que é padrão na prática clínica para apoio ao diagnóstico do câncer de mama por imagem desde 1960, termografias que vem sendo proposta como método complementar à mamografia, consiste em uma câmera capaz de mensurar a temperatura do tecido (SILVA, 2022), entre outras formas que serão apresentadas posteriormente, uma visão que pode ser treinada para identificar os mínimos resquícios de padrão é uma ferramenta promissora.

O processamento digital de imagens é uma técnica que ganhou notoriedade no mercado, assim como a tecnologia está bem associada aos avanços médicos e fármacos, fazer uso de uma IA para o auxílio em diagnósticos mostra uma grande realidade para a construção de diagnósticos mais rápidos e precisos, facilitando e agilizando o processo de tratamento necessário.

Essa visão computacional demonstra uma pequena parcela de todo o processo e capacidade com a implantação de sistemas que façam uso de CNNs e que sejam construídos, treinados e utilizados para ver aquilo que o ser humano deixaria passar.

1.4 Trabalhos relacionados

Neste tópico, são apresentados os trabalhos que contribuíram para a definição metodológica e a tomada de decisões quanto às técnicas utilizadas neste estudo. A análise de pesquisas anteriores permitiu extrair informações relevantes que fundamentam desde a escolha dos padrões de detecção por imagem até o reforço da adoção de redes neurais convolucionais (CNNs) em aplicações médicas.

De acordo com Machado (2024), a mamografia é considerada o principal exame no diagnóstico do câncer de mama, sendo reconhecida como o padrão ouro. Além disso, o uso de técnicas de inteligência artificial na análise de mamografias pode atingir níveis de acurácia, sensibilidade e especificidade semelhantes ou superiores aos de radiologistas com menor experiência clínica.

Segundo F. F. R. D. Ó (2023), as CNNs representam a abordagem de inteligência artificial mais aplicada em ensaios clínicos voltados à análise de

imagens oncológicas, demonstrando resultados positivos. Esses dados corroboram a literatura recente, que posiciona as CNNs como o estado da arte em tarefas de segmentação e classificação de imagens médicas.

1.5 Resumo da metodologia

O presente trabalho trata-se de uma pesquisa aplicada, de abordagem quantitativa e de natureza experimental, visando analisar o desempenho de modelos de CNNs para análise das imagens médicas de mamografias buscando confirmar os objetivos propostos.

Para isso, foi selecionado o banco de dados que apresentasse uma boa quantidade e qualidade de imagens, para a escolha dos modelos, foram analisados os que apresentassem uma estrutura com funcionamento similar, mas que também pudesse ser identificado a capacidade de evolução dependendo da escolha do modelo para o caso de uso específico.

Com isso foram selecionados o *AlexNet* e o *ResNet*, apesar de sua diferenças, o objetivo seria mostrar a eficiências de algoritmos de análise de imagens, esses então apresentaram-se como bons candidatos pois, O *AlexNet*, por ser um modelo clássico e amplamente estudado, permitiria uma análise comparativa sólida com uma base bem estruturada e mais simples de CNN, enquanto o *ResNet50*, com sua arquitetura mais moderna e profunda, proporciona a oportunidade de investigar o desempenho de modelos mais avançados no mesmo contexto.

Essa combinação vai abranger tanto ao objetivo de aplicar algoritmos distintos para validação de desempenho quanto à intenção de obter compreensões práticas sobre suas eficiências no auxílio ao diagnóstico precoce.

1.6 Organização e estrutura do trabalho

Esta pesquisa está organizada em cinco capítulos, descritos a seguir. O primeiro é esta Introdução. O capítulo dois destina-se ao Referencial Teórico, onde

será apresentada toda a teoria sobre o câncer de mama: História, Riscos, Níveis, Formas de diagnóstico e Tratamento, e também os dados referentes a Inteligência Artificial, de seus conceitos básicos até seus modelos e aplicações.

No terceiro é a Metodologia, onde será abordado a base de dados que será utilizada para este trabalho, as formas e métodos que foram aplicados para prepará-los e como foi a execução dos modelos de CNNs escolhidos. No quarto foi separado para Resultados e Discussões onde serão apresentados os resultados dos treinamentos e processos realizados com o *AlexNet* e com o *ResNet50*.

No quinto ficaram as Considerações Finais onde estão os resultados finais e a conclusão, seguido das Referências.

2 REFERENCIAL TEÓRICO

Neste capítulo serão apresentados os conceitos básicos sobre o câncer de mama e inteligência artificial, os quais irão nortear o entendimento necessário para este estudo.

2.1 Câncer de mama

Com o passar dos tempos os conhecimentos sobre as doenças têm crescido consideravelmente, muitas coisas são descobertas e outras desvendadas, sobre o câncer não é diferente. Ele que se origina a partir de uma mutação genética, ou seja, de uma alteração no DNA da célula, essa célula recebe instruções erradas para realizações de suas atividades (SILVA, 2022). Assim causando um acúmulo de células defeituosas e com isso originando, em alguns casos, os tumores.


O histórico sobre o câncer denota a milhares de anos. Embora seja difícil determinar exatamente quando a doença surgiu, existem muitos registros antigos que sugerem que o câncer já afetava as pessoas no passado. Os primeiros relatos sobre o câncer encontrados em papiros egípcios, datam de cerca de 3000 a.C. Esses documentos mencionam tumores que se assemelham aos cânceres de mama e de útero (F. F. R. D. Ó, 2023).

Notou-se que o câncer possui três estágios de desenvolvimento: o primeiro ou estágio de iniciação, onde os agentes carcinogênicos provocam modificações em genes especiais, genes esses, denominados de proto-oncogenes, que regulam os processos biológicos e atuam como fatores de crescimento (MACHADO, 2024; INCA, 2024a).

No segundo, é chamado de estágio de promoção, onde os proto-oncogenes ativados são transformados em oncogenes, que levam ao aparecimento de células cancerígenas. Transformando-as em células malignas por meio de um processo lento e gradual, podendo ser interrompido pela suspensão do contato com agentes promotores ou por genes supressores de tumor (MACHADO, 2024; INCA, 2024a).

O terceiro estágio é a progressão, ou metástase, caracterizado pela multiplicação descontrolada e irreversível das células cancerígenas, que podem invadir tecidos adjacentes e se disseminar pelo corpo (MACHADO, 2024; INCA, 2024a). Para analisar, observe a figura 1 a seguir essas etapas do desenvolvimento.

Figura 1 – Estágios de desenvolvimento do câncer.



Fonte: Machado (2024).

Acometendo o tecido da mama, principalmente os lobos e ductos mamários, o câncer de mama, por meio de um crescimento rápido, em alguns casos, e desordenado de células deformadas, formará um tumor, apresentando sinais e sintomas como lesões comumente indolores, fixas e com bordas irregulares, edema, eritema, nódulo em uma das mamas ou na axila, mudança no aspecto da pele e produção de secreção sanguinolenta ou serosa pelos mamilos (MACHADO, 2024).

A maioria dos casos, quando tratados adequadamente e em tempo oportuno, apresentam bom prognóstico e possibilitam melhores resultados estéticos (INCA, 2024a).

2.1.1 Fatores de risco

Segundo o INCA (2024a), dos fatores de risco a idade é o maior deles (cerca de quatro em cada cinco casos ocorrem após os 50 anos), os outros fatores dividem-se em: fatores ambientais e comportamentais, fatores da história reprodutiva e hormonal, e fatores genéticos e hereditários. Estes fatores são descritos a seguir:

- **Fatores Comportamentais/Ambientais**

São aqueles ligados ao meio que a pessoa está inserida e ao seu estilo de vida, alguns exemplos são o sobrepeso e obesidade, uma pessoa sedentária que não realiza atividades físicas, o consumo de bebidas alcoólicas, a alta ou frequente exposição à radiação ionizante (raio-X, tomografia, radioterapia), com evidências sugestivas de aumento de risco, o tabagismo (Observatório da APS, 2024).

O INCA ainda aponta mais alguns meios, onde profissionais como cabeleireiro, operadores de rádio e telefone, trabalhadores noturnos, da indústria da borracha, plástico, química, refinaria de petróleo e manufatura de pvc têm maior risco de ter câncer de mama (INCA, 2024a).

- **Fatores Endócrinos/História Reprodutiva**

São aqueles que estão ligados ao processo hormonal, como exemplos, a primeira menstruação cedo, ocorrendo antes dos 12 anos de idade, em contrapartida, menopausa depois dos 55, a primeira gravidez após os 30 anos ou não ter filhos, o uso de contraceptivos hormonais e ter feito reposição hormonal, principalmente por mais de 5 anos após a menopausa (Observatório da APS, 2024; INCA, 2024a).

- **Fatores Genéticos/Hereditários**

Estes fatores, estão diretamente voltados ao histórico familiar como, histórico de câncer de ovário, casos de câncer de mama, ainda mais se foi antes dos 50, histórico de caso de câncer de mama em homens, alteração genética dos genes BRCA1 e BRCA2 (que são genes responsáveis pela produção das proteínas que auxiliam na reparação do DNA danificado) (INCA, 2024a; Sérgio Franco, 2023).

Tendo em vista os fatores comportamentais/ambientais, nota-se que se faz possível uma busca pela diminuição da incidência dos casos, para isso, adotando um estilo de vida mais saudável.

2.1.2 Métodos de diagnóstico

Quando se trata dos métodos de diagnóstico do câncer de mama, pode-se analisar duas versões de visão sobre o processo: a versão do paciente e a versão do profissional de saúde.

Na versão do paciente alguns processos de investigações são seguidos até o diagnóstico definitivo, nestes além do exame clínico das mamas, alguns exames de imagem podem ser recomendados, como mamografia, ultrassonografia ou ressonância magnética (INCA, 2024a). Existe um passo que pode agilizar a busca médica, além dos exames de rotina, o autoexame. Deve-se ficar alerta aos sintomas, em caso de um ou mais identificados, ir à procura de assistência médica.

Analisando a versão do profissional de saúde para o diagnóstico do câncer de mama, ele é estruturado em um tripé: exame clínico, exame de imagem e análise histopatológica (análise microscópica dos tecidos para a detecção de possíveis lesões existentes). Importante salientar a necessidade da realização de uma boa anamnese, exame físico e o complemento por meios de exames de imagens (mamografia, ultrassonografia ou ressonância magnética) para avaliar a necessidade de realizar a biópsia da lesão (SILVA, 2022; INCA, 2024a).

Alguns desses métodos de diagnósticos são descritos a seguir:

- **Autoexame**

Uma ação que pode ser decisiva na busca pelo acompanhamento precoce de um possível caso. Ao notar alguns sintomas anormais como, um nódulo palpável na mama, a pele avermelhada, alterações no mamilo, como a saída anormal de secreção, dor ou inchaço em parte ou em toda a mama, ou nódulos na região cervical ou na axila (Observatório da APS, 2024). A seguir uma imagem ilustrativa de como fazer autoexame das mamas.

Figura 2 – Autoexame das Mamas



Fonte: FDG Cirurgia Plástica (2024).

- **Mamografia**

Mamografia (MMG) é uma imagem radiográfica das mamas feita por um equipamento de raios X, possibilitando a detecção antes mesmo dos sintomas evidentes, ou seja, antes mesmo que possa surgir algum fator identificável no autoexame, o que fortalece o incentivo na implementação da mamografia de rastreamento (INCA, 2024a). Assim como todos os procedimentos, principalmente os que envolvem a exposição à radiação, as mamografias, segundo o INCA, apresentam benefícios e riscos.

Os pontos positivos estão em permitir um tratamento menos agressivo e diminuir a taxa de mortalidade para câncer de mama, em função de um tratamento precoce, enquanto aos riscos, vão de diagnósticos incorretos, onde é identificado um falso positivo, a doença é uma suspeita, mas não se confirma, gerando um alarme falso e ansiedade e estresse, ou um falso negativo, onde a doença existe mas não é identificada (INCA, 2024a; MACHADO, 2024).

No entanto, apesar da MMG ser tomada como padrão para o diagnóstico do câncer de mama, durante muito tempo não houve um modelo padronizado de interpretação de imagem. Somente com o desenvolvimento do *Breast Imaging Reporting and Data System* (BI-RADS) criado pelo *American College of Radiology* (ACR) que surgiu uma abordagem uniforme para relatar patologias mamárias através de imagens (MACHADO, 2024).

O BI-RADS é definido por categorias numeradas de 0 a 6 que indicam qual é o risco desse exame evidenciar um câncer de mama, mas não evidenciam o tipo de tumor (MACHADO, 2024). No quadro a seguir será possível analisar a classificação.

Quadro 1 – Classificação BI-RADS

Categoria	Conclusão
BI-RADS 0	Incompleto.
BI-RADS 1	Negativo.
BI-RADS 2	Benigno.
BI-RADS 3	Provavelmente benigno.
BI-RADS 4	Suspeitos para câncer.
BI-RADS 5	Altamente suspeitos para câncer.
BI-RADS 6	Câncer comprovado.

Fonte: *Star Med* (2024).

- **Ultrassonografia**

A ultrassonografia mamária é um exame de imagem não invasivo que, como o próprio nome sugere, faz uso de ondas sonoras de alta frequência para detectar alterações nos tecidos e identificar nódulos, cistos, espessamento do tecido mamário, entre outras condições. O exame é indolor, porém ele não substitui a MMG, sendo assim indicado em algumas situações específicas como, pacientes jovens que não tem alterações nas mamas, mulheres que não podem receber radiação ionizante, gestantes, entre outras (Dasa, 2024).

Apesar de ser capaz de diagnosticar casos de câncer de mama assintomáticos e não identificados por meio do exame físico ou mamografia, a ultrassonografia possui algumas limitações, sendo uma delas os altos custos globais e outra o número relativamente alto de investigações ou cirurgias sem que chegue ao diagnóstico de câncer, os falsos positivos (SILVA, 2022).

- **Ressonância magnética**

A ressonância magnética das mamas se mostrou uma técnica sensível para essa análise, se mostrando muito eficiente na detecção e diagnóstico precoce, porém sua sensibilidade é tanta que detecta até lesões benignas, mas não as

diferencia, fazendo-se necessário uma biópsia para a exclusão da possibilidade de tumor. Dessa forma, a ressonância magnética tem indicações específicas, principalmente para as mulheres com maior risco de desenvolver ou com diagnóstico de câncer de mama (Cancer de Mama Brasil, 2024).

Contudo, apesar de a ressonância magnética apresentar essa enorme capacidade de sensibilidade para diagnosticar lesões, principalmente para definir com precisão o tamanho do tumor, a sua adição ao exame de mamografia eleva os custos (SILVA, 2022).

- **Termografia**

A termografia é uma técnica auxiliar no processo de diagnóstico do câncer de mama, sendo uma técnica não invasiva e que ocorre pela análise da radiação infravermelha detectada por câmera do corpo a ser analisado, buscando registrar a radiação térmica emitida pela superfície da pele da paciente, apresentando na região uma distribuição de temperatura que será mapeada (SILVA, 2022).

Reforçando que a mamografia ainda é o método mais eficiente no diagnóstico e que a termografia não substituirá-la, servindo como uma ferramenta para análise em conjunto. Sendo em alguns casos não indicada para fazer parte de diagnósticos, mesmo que em conjunto, isolando-a apenas a ser restrita ao ambiente de pesquisa (Medicina SA, 2024).

2.1.3 Métodos para tratamento

Avanços importantes aconteceram nas últimas décadas para a medicina, principalmente formas menos mutiladoras de procedimentos invasivos. Ainda assim, as formas de tratamento variam para cada organismos, como características biológicas, bem como as condições da paciente (idade, status menopausal, comorbidades e preferências), com isso tem-se buscado formas de tratar cada caso individualmente (INCA, 2024c).

O prognóstico do câncer de mama depende do tempo de identificação, assim como o nível de desenvolvimento do tumor. Quando o diagnóstico é precoce o tratamento tem maior potencial curativo. Quando há evidências de metástases, ou seja, mais avançado, o tratamento tem por objetivos principais prolongar a sobrevida e melhorar a qualidade de vida (INCA, 2024a).

As modalidades de tratamento variam de cirurgia e radioterapia (além de reconstrução mamária), a quimioterapia, hormonioterapia e terapia biológica, tudo baseado no diagnóstico do estado do tumor.

Com isso o INCA separa por estádios a aplicação das modalidades de tratamento citadas a pouco, onde ao analisar os níveis de desenvolvimento as decisões terapêuticas serão tomadas embasadas em toda a análise do conjunto (paciente/nível do tumor).

No estágio I e II a conduta habitual é a cirurgia, com retirada do tumor ou a mastectomia, retirada da mama (onde nesse caso deve sempre ser considerada a reconstrução). Com a possibilidade de que na relação tumor/mama, seja desfavorável para cirurgia conservadora, mesmo que tumores em estágios iniciais, o tratamento neoadjuvante¹ pode ser indicado na tentativa de se fazer um *downstaging*² da doença e permitir uma cirurgia conservadora. Essa indicação deve levar em consideração o subtipo tumoral. Após a cirurgia, o tratamento complementar com radioterapia pode ser indicado em algumas situações. Analisando o risco de recorrência (INCA, 2024c; INCA, 2024a).

Ainda segundo as mesmas fontes, no estágio III entram pacientes com tumores maiores. Nessa situação, o tratamento sistêmico (na maioria das vezes, com quimioterapia) é a modalidade terapêutica inicial. Após resposta adequada, segue-se o tratamento local com cirurgia e radioterapia.

No estágio IV, é fundamental que a decisão terapêutica busque o equilíbrio entre a resposta tumoral e o possível prolongamento da sobrevida, tendo em mente os potenciais efeitos colaterais decorrentes do tratamento. A atenção à qualidade de vida da paciente deve ser preocupação dos profissionais de saúde ao longo de todo o processo terapêutico (INCA, 2024c; INCA, 2024a).

2.1.4 Índices de casos e mortalidade de câncer de mama no Brasil


A prevenção e a detecção precoce estão entre as principais estratégias para combater e reduzir a elevada taxa de mortalidade por câncer de mama no Brasil (Conselho Nacional de Saúde, 2024). O câncer de mama é a primeira causa de

¹ Neoadjuvante significa que um tratamento, geralmente quimioterapia ou radioterapia, é administrado antes da cirurgia principal.

² Downstaging traduzindo do inglês significa "redução do estadiamento". Refere-se à diminuição do estágio clínico de um tumor após o tratamento, indicando resposta positiva à terapia.

morte por câncer em mulheres no Brasil, com patamares diferenciados entre as regiões (INCA, 2024b), apresentado no gráfico a seguir.


Gráfico 1 – Taxas de mortalidade por câncer de mama, ajustadas por idade pela população mundial, por 100 mil mulheres. Brasil e Regiões, 2000 a 2021



Fonte: INCA (2024b).

As taxas de mortalidade por câncer de mama são mais elevadas entre as mulheres de idade mais avançada, porém a mortalidade proporcional é maior no grupo de 50 a 69 anos, correspondendo cerca de 45% do total de óbitos por câncer de mama (INCA, 2024b), que podem ser observados no gráfico 2 a seguir.

Gráfico 2 – Mortalidade proporcional por câncer de mama segundo faixa etária, Brasil 2000 a 2021



Fonte: INCA (2024b).

Reduzir a mortalidade é a principal meta do Brasil, segundo Mônica de Assis destaca ao falar da importância do diagnóstico precoce para e do tratamento em tempo adequado para redução de óbitos,

O nosso problema é a doença avançada. Segundo os registros, a gente tem 41% de casos, que quando chegam para tratar estão nos estádios 3 e 4 da doença, que é uma fase mais avançada (Conselho Nacional de Saúde, 2024).

Sabe-se então que haverá desafios que precisam ser superados para que consigam minimizar as taxas de mortalidade, desta são, manter as mulheres sempre bem informadas; a quebra de tabus quanto ao câncer; realizar diagnóstico de lesões suspeitas da mama no momento apropriado; início do tratamento em até 60 dias; mamografia de qualidade; ter garantia a tratamento por equipe multidisciplinar e, se for o caso, receber cuidados paliativos (Conselho Nacional de Saúde, 2024).

2.2 Conceitos fundamentais de Inteligência Artificial (IA)

Inteligência Artificial (IA) é um campo interdisciplinar que busca desenvolver sistemas capazes de realizar tarefas que normalmente requerem inteligência humana (ZEEV, 2024). Compreendendo sistemas com características associadas à inteligência do comportamento humano, como por exemplo a percepção, processamento de linguagem natural, solução e planejamento de problemas, aprendizagem e adaptação, e agindo sobre o meio ambiente (BRITO et al., 2021). Com suas vastas possibilidades de aplicação, principalmente no mundo que atualmente vem ficando cada vez mais virtualizado, novos horizontes de implementações são explorados.

Com sua origem em meados dos anos 50, quando visionários começaram a explorar a ideia de criar máquinas inteligentes capazes de pensar e aprender como humanos. Dentre eles, destaca-se Alan Turing, um matemático britânico, que com seus estudos e teorias desenvolveu a "Máquina de Turing", contribuição que foi fundamental para a compreensão e entendimento com impacto duradouro no campo da IA.

O teste consistia em um interrogador humano identificar qual respondente é a máquina, dentre um humano e uma máquina. Se o interrogador não for capaz de discernir as respostas da máquina das respostas do humano com mais frequência do que seria esperado por acaso, considera-se que a máquina passou. Isso trouxe um grande avanço, estabelecendo fundamentos teóricos da tecnologia voltada para o desenvolvimento da Inteligência Artificial (ZEEV, 2024; Ó, 2023).

De acordo com Ó (2023) e ZEEV (2024), o campo da IA tomou forma oficialmente na década de 1950 com o nascimento da disciplina e a histórica Conferência de *Dartmouth* realizada em 1956, onde o termo "Inteligência Artificial" foi criado. Durante debates e discussões intensivas, os participantes delinearam os fundamentos e objetivos da IA.

Com isso em vista, Campos (2020) traz uma definição para "inteligência artificial", segundo ele, além das enormes definições sobre o significado de inteligência, o que se deve recorrer quando se tratar da IA é, "Inteligência é a capacidade de aprender." Assim, ele nos apresenta que qualquer programa de computador que seja capaz de aprender – seja um jogo, um sistema de

reconhecimento a um sistema de controle autônomo – é dito inteligente, sob esta visão.

Analisando suas classificações podemos separar como, IA específica ou "fraca", IA geral ou "forte", *Machine learning* e *Deep learning* (VIEZZER, 2022):

- **IA específica ou "Fraca":** A IA definida como “Fraca” é aquela que não consegue realizar conexões lógicas por sua própria vontade, necessitando da iniciativa humana para seu desenvolvimento. Por esse motivo, muitos especialistas não consideram esta como IA propriamente dita. No entanto, para outros, o termo correto deveria ser “Limitada” ou “Específica” e não "Fraca", pois indicariam melhor as situações que estes sistemas são aplicados (VIEZZER, 2022).

São exemplos destes sistemas a Siri (assistente da *Apple*), a *Cortana* (assistente dos sistemas *Windows*), a *Alexa* (da *Amazon*) e diversos outros, fazendo parte dos sistemas mais utilizados atualmente (VIEZZER, 2022).

- **IA geral ou "forte":** Apresenta funções similares às de um cérebro humano em toda sua complexidade, sendo assim capaz de tomar suas próprias decisões sem a necessidade de suporte ou intervenções humanas. Somente assim poderia ser classificada como uma IA "forte", onde a máquina ou sistema possa aprender sozinha e execute diversas funções, aprendendo com base no ambiente em que se encontra (VIEZZER, 2022).

Então sobre isto, Viezzler (2022) cita um experimento de John Searle, que apresenta a teoria do Quarto Chinês. Neste experimento ele demonstra que responder correto não significa aprender e com base nesta teoria, para ser a IA "forte", ela deveria ter uma mente e certa consciência, para que consiga elaborar entendimentos e respostas sobre dados aspectos, entretanto Searle não acredita que esse nível venha a ser alcançado, pois segundo ele, o sistema não possui a capacidade de perceber o lado semântico.

- ***Machine learning* (ML):** Em tradução livre "Aprendizado de Máquina", no qual o próprio nome já induz, a máquina irá aprender e tomar decisões. Podemos separar o ML como, algoritmos supervisionados, não

supervisionados e semi-supervisionados ou por reforço. No aprendizado supervisionado, os algoritmos são treinados em dados rotulados, onde cada exemplo de treinamento possui uma entrada e a saída esperada correspondente. Já o não supervisionado, não existem rótulos e o algoritmo irá buscar por padrões ocultos nos dados. Quanto ao semi-supervisionado, ele é uma combinação dos dois anteriores, onde usará uma pequena quantidade de dados rotulados e uma grande parte de não rotulados. Enquanto o por reforço, o aprendizado se daria pelo sistema de tentativa e erro, por conta própria do algoritmo. (Ó, 2023).

- **Deep learning (DL):** Consiste em uma técnica de ML que se baseia em redes neurais artificiais profundas. Essas redes são compostas por múltiplas camadas de neurônios interconectados que aprendem a reconhecer padrões complexos nos dados (Ó, 2023; VIEZZER, 2022).

Esses conceitos são fundamentais para entender como as tecnologias de aprendizado de máquina e redes neurais podem ser aplicadas na análise de imagens de mamografias, visando diagnósticos mais precisos e precoces.

2.2.1 Aplicação da Inteligência Artificial na área médica

A IA mostrou e mostra sua vastidão de possíveis aplicações, na medicina não é diferente, a observação e capacidade de auxílio vem sendo analisada e explorada ultimamente. Nela, a IA pode auxiliar em diagnósticos, prever desfechos clínicos, personalizar tratamentos e otimizar processos administrativos, entre outras aplicações (Conselho Federal de Medicina, 2023).

Em sua descrição Ó (2023) demonstra a grande variedade de situações onde o uso de IA pode ser eficiente tais como: Triagem e detecção precoce, Personalização de tratamento, Prognóstico e previsão de resultados, Descoberta de medicamentos, e em Gerenciamento e monitoramento do paciente. Cada caso desses apresenta características que os fazem eficientes e apontando seus benefícios.

Ainda segundo o autor, para a detecção precoce o benefício seria o auxílio na precisão e eficiência dos modelos e para a triagem é a análise dos fatores de risco e do histórico familiar, no tratamento personalizado seria a possibilidade de um

tratamento ajustado para cada indivíduo, no prognóstico seria a capacidade de prever a evolução dos casos e ajudar no tratamento, na descoberta de medicamentos é sobre a capacidade da análise de grandes capacidades de dados, possibilitando a descoberta de novos fármacos, e sobre gerenciamento de paciente, o próprio nome já é bem auto explicativo.

2.2.2 Inteligência Artificial aplicada ao diagnóstico e tratamento do câncer

Conhecendo o poder de capacidade da IA com seus métodos de aprendizagem e processamento, nota-se que a mesma pode ajudar a melhorar a precisão e a eficiência no diagnóstico de câncer. Analisando imagens, como radiografias, tomografias computadorizadas e/ou ressonâncias magnéticas, para identificar características e padrões associados ao câncer ela poderá auxiliar em um diagnóstico com mais precisão em um menor período de tempo (Ó, 2023).

Tratamentos são específicos para cada causa e como aponta o INCA (2024a), os conhecimentos sobre as variadas formas de apresentação da doença hoje em dia são maiores. Existem vários subtipos de câncer de mama e cada um requer tratamento específico e individualizado.

A IA pode, nesse sentido, ajudar a personalizar um tratamento de acordo com as características de cada indivíduo. Usando algoritmos de IA para analisar dados clínicos, genéticos e histopatológicos a fim de identificar perfis moleculares do tumor e prever a resposta a diferentes tratamentos. Auxiliando os médicos nas tomadas de decisões sobre quais abordagens irão trazer um melhor resultado para cada paciente (Ó, 2023).

Segundo as informações do INCA (2024a), grande parte dos casos de câncer de mama podem ser detectados nas fases iniciais, aumentando assim a possibilidade de tratamentos menos agressivos e com taxas de sucesso satisfatórias.

Usando algoritmos de IA para analisar fatores de risco, histórico familiar e dados genéticos a fim de identificar grupos de alto risco que requerem monitoramento e exames adicionais (Ó, 2023). Possibilitando assim grandes chances de detecção precoce, auxiliando em tomadas de decisões menos drásticas e procedimentos menos desgastantes para a paciente.

2.3 Algoritmos de classificação de imagens cancerígenas

A IA na análise de imagens utiliza de algoritmos e técnicas para que os computadores sejam capazes de compreender e extrair as informações relevantes de imagens digitais, possibilitando seu uso em uma variedade de tarefas, como reconhecimento de objetos, detecção de padrões, segmentação, classificação, localização e muito mais (Ó, 2023).

Em estrutura isso se trata de uma *Deep Neural Network* (DNN), quando o modelo possui muitas camadas e geralmente a saída de uma é a entrada de outra, ao final de todas as camadas o resultado será uma característica extraída desse processo (SILVA, 2022). Para a análise de imagem e fazendo uso de ML, um modelo de DNN muito conhecido e empregado são as Redes Neurais Conclucionais (CNNs).

2.3.1 Principais algoritmos aplicados ao diagnóstico precoce do câncer de mama


As redes neurais convolucionais (CNNs) são redes neurais especializadas em processar dados de entrada bidimensionais e também tridimensionais, como imagens. São compostas por várias camadas, incluindo camadas de convolução, de agrupamento (*pooling*) e de classificação.

A camada de convolução é responsável por aplicar filtros às imagens, buscando capturar as características relevantes em diferentes escalas e localizações. A camada de pooling reduz a dimensionalidade das características, preservando as informações mais importantes. Por fim, a camada de classificação utiliza essas características para realizar uma determinada tarefa específica, como classificação de objetos em uma imagem (Ó, 2023). Com isso, o modelo treinado será capaz de encontrar padrões em imagens rotuladas. Seguindo com as CNNs, abordaremos brevemente algumas arquiteturas.

A *AlexNet* foi desenvolvida por Alex Krizhevsky. Ela alcançou resultados significativamente melhores do que os métodos anteriores na competição *ImageNet*, que consiste em classificar objetos em um conjunto de imagens com milhões de exemplares. O que impulsionou a popularização das CNNs e o avanço das aplicações de IA em visão computacional (Ó, 2023).

Sua função de ativação também aumenta seu diferencial, pois ao invés de transformar qualquer valor de entrada em um valor entre 0 e 1, como a *Sigmoid* que era o padrão anterior para redes neurais tradicionais fazia, a *Rectified Linear Unit* (ReLU) transforma os valores negativos em zero, enquanto mantém os positivos (TRICKS, 2017). Observe o modelo da arquitetura da *AlexNet* na Figura 3 a seguir.

Figura 3 – Arquitetura da AlexNet



Fonte: TRICKS (2017).

A *VGGNet* foi outra CNN importante, desenvolvida por *Simonyan* e *Zisserman* em 2014. Essa arquitetura introduziu a ideia de usar camadas de convolução com filtros muito pequenos e repetidos várias vezes, resultando em uma *deep learning* (DL). A *VGGNet* alcançou um excelente desempenho em muitas tarefas de análise de imagens e servindo de base para o desenvolvimento posterior de novas arquiteturas (Ó, 2023).


A *VGGNet* apresenta melhoria em relação ao *AlexNet* ao substituir filtros grandes de tamanho de *kernel* (11 e 5 na primeira e segunda camada convolucional, respectivamente) por vários filtros de tamanho de *kernel* 3X3 um após o outro (TRICKS, 2017).

ResNet é uma rede residual que tem como objetivo reduzir o problema do gradiente que desaparece (*Vanish Gradient*³), essa arquitetura introduziu blocos residuais que permitiam o treinamento de redes muito mais profundas, superando problemas de degradação de desempenho que surgiam com o aumento do número de camadas.

³ Vanish Gradient acontece quando os sinais de erro se tornam muito pequenos ao passar pelas camadas de uma rede neural, dificultando o aprendizado das camadas iniciais.

Na *ResNet* o mapeamento de identidade permite que o modelo ignore uma camada CNN se a mesma não for mais necessária, ajudando a evitar o problema de sobreajuste (*overfitting*⁴) ao conjunto de treinamento (Ó, 2023; SILVA, 2022). A *ResNet50* é uma forma mais compacta da rede residual com 50 camadas. O uso de conexões de atalho apresenta como vantagem o valor estático para o número de parâmetros e também o da complexidade computacional. A seguir, a figura 4 que ilustra o funcionamento do bloco da *Resnet*.

Figura 4 – Modelo de bloco *ResNet*



Fonte: TRICKS (2017).


You only look once (YOLO) é um algoritmo de detecção de objetos, apresentado em 2015 por *Joseph Redmon*, *Santosh Divvala*, *Ross Girshick* e *Ali Farhadi* em seu famoso artigo de pesquisa "*You Only Look Once: Detecção de objetos unificada e em tempo real*".

Para isso, o algoritmo divide a imagem em um sistema de grade, onde em cada célula, são preditas N caixas delimitadoras com determinado nível de confiança contendo as probabilidades de cada classe. O modelo YOLO é um detector de um estágio, em que a predição de caixas delimitadoras está conectada à predição dos rótulos de classe, aprimorando assim, a velocidade de inferência da mesma

⁴ Overfitting no português sobreajuste é quando um modelo se ajusta demais aos dados de treino, perdendo a capacidade de prever corretamente novos dados.

(DataCamp, 2024; Ó, 2023). Acompanhe esse processo analisando a Figura 5 a seguir.

Figura 5 – Arquitetura YOLO



Fonte: DataCamp (2024).

3 METODOLOGIA

Neste capítulo, serão abordadas as questões referentes à caracterização da pesquisa, incluindo seu caráter aplicado, a abordagem quantitativa e a natureza experimental. Será apresentada a base de dados utilizada, bem como os critérios adotados para sua seleção. O estudo busca demonstrar como é possível aplicar técnicas de Inteligência Artificial, mais especificamente CNNs, para a análise de imagens de mamografias a fim de contribuir para o diagnóstico precoce do câncer de mama. Além disso, serão descritos os processos de coleta, organização e tratamento dos dados, assim como a estruturação geral do trabalho.

3.1 Métodos para seleção de atributos e classificação

Para este trabalho, foram propostas técnicas para a análise e extração de dados das imagens de mamografias utilizando redes neurais convolucionais, como também técnicas de treinamento de aprendizagem de máquina.

Neste capítulo foi apresentada a metodologia utilizada para o desenvolvimento deste trabalho, assim como a descrição da realização das buscas: inicialmente a etapa de extração de atributos, usando técnicas de extração de imagens; passando pela etapa da padronização de tamanhos e separação por seus atributos; e por fim a etapa de agrupamento, criando os arquivos base para treinamento e testes posteriormente.

A metodologia foi dividida nas seguintes etapas: descrição da base de dados das imagens de mamografias, pré-processamento das imagens (seleção das imagens, extração de atributos, seleção de atributos e balanceamento das classes).

Nessa organização as imagens foram divididas em duas categorias, treino apresentando 6145 imagens e validação com 1537, onde nesse são separados em duas categorias, imagens com e sem a presença de câncer.

3.2 Base de dados

Na busca por dados para o presente trabalho, será utilizada a plataforma *Kaggle* (INC., 2024), a maior comunidade de ciência de dados e aprendizado de


máquina do mundo. Com isso, ao treinar os modelos com os dados desses datasets, esperasse que ao final ele tenha uma taxa positiva na identificação de câncer de mama, mostrando-se assim eficiente no auxílio médico. Ao analisar as imagens o algoritmo terá que apresentar uma resposta a ela, assim identificando a presença em casos positivos, ou ausência nos negativos, dos vestígios de câncer de mama na imagem.

Um conjunto de dados escolhido é composto por imagens provenientes de dois renomados conjuntos: *Digital Database for Screening Mammography* (DDSM) e *Cancer Imaging Archive's Breast Cancer Digital Database* (CBIS-DDSM). Esses conjuntos são amplamente reconhecidos na pesquisa de imagens médicas, especialmente para a detecção de câncer de mama (Kaggle User, 2024).

As imagens utilizadas são resultantes de exames de mamografias, que é o tipo de exame mais eficiente para a detecção e já foram pré-processadas e convertidas para o formato 299x299 através da extração das regiões de interesse (ROIs). Os dados estão armazenados em arquivos *TFRrecords*, um formato otimizado para *TensorFlow* (Kaggle User, 2024). Conforme ilustrado nas Figuras 6 e 7, observa-se a diferença entre uma imagem de mamografia sem anomalias e outra com anomalia.

Figura 6 - Exemplo de mamografia da classe negativa (sem anomalia).


Rótulo: 0



Fonte: *Elaborado pelo autor (2025), imagem do dataset.*

Figura 7 - Exemplo de mamografia da classe positiva (com anomalia).

Rótulo: 1



Fonte: *Elaborado pelo autor (2025), imagem do dataset.*

Com isso, para estudo usando o *AlexNet* e *ResNet*, a otimização fica menos trabalhosa, precisando configurar os modelos para trabalhar com esse conjunto de dados.

O conjunto de dados contém 5 arquivos *TFRecords* e ainda também arquivos *numpy* com as imagens e dados clínicos, onde destes foram extraídas as imagens correlacionando-as com o arquivo de dados clínicos para e então organizadas para treino e teste, onde deste foram separados em 80/20 para treinamento e validação, depois desses ajustes para treino e teste, com uma base de um pouco mais de 7 mil imagens foram analisadas para o pré-processamento. Esse desbalanceamento na distribuição de classes é um fator importante a ser considerado, pois pode impactar tanto o treinamento quanto a avaliação do modelo (Tran Thi Phuong Ngan, 2024). A seguir observe a figura 6, selecionando de onde as imagens foram extraídas e a os dados clínicos de referência.

3.3 Pré-processamento dos dados

A presente seção aborda a forma de tratamento dos dados que serão selecionados para as futuras análises, treinamento e validação. O *dataset* consiste em imagens de dois conjuntos: imagens negativas do *DDSM* e imagens positivas do *CBIS-DDSM*.

A base de dados utilizada foi obtida da plataforma *Kaggle*, composta por imagens de mamografias e seus respectivos rótulos, originalmente armazenados em arquivos no formato *.tfrecords* e também em arquivos *.npy*, contendo os dados em arrays prontos para uso.

Para facilitar o manuseio e visualização, optou-se por utilizar o arquivo *.npy*, do qual foram extraídas aproximadamente 7.682 imagens e seus rótulos binários correspondentes, indicando presença ou ausência de sinais de câncer de mama.

As imagens foram então convertidas e organizadas em diretórios separados para treino e validação, conforme a estrutura esperada pelo gerador de dados *ImageDataGenerator* do *TensorFlow*. A divisão entre os conjuntos de treino e teste foi realizada manualmente, respeitando uma proporção adequada para validação do modelo.

Depois disso as imagens resultantes foram rotuladas de acordo com os critérios que podem ser analisados no quadro 2 a seguir, já no quadro 3 logo após é possível analisar os rótulos referentes às classes presentes em cada imagem no

dataset. Com as etapas de pré-processamento concluídas, as imagens estão agora preparadas para serem utilizadas no treinamento e validação do modelo.

Quadro 2 - Rótulos da presença de câncer

Rótulos	Valores
0	negativo
1	positivo

Fonte: Elaborado pelo autor (2025).

Quadro 3 - Rótulos de multi classes

Rótulos	Descrição
multi classe 1	calcificação benigna
multi classe 2	massa benigna
multi classe 3	calcificação maligna
multi classe 4	massa maligna

Fonte: Elaborado pelo autor (2025).

Ainda nessa parte foi analisado que o poder computacional disponível para os processamentos iriam influenciar nos resultados, não diretamente nos números, mas o tempo de execução e ainda com as modificações necessárias para ajustes ao decorrer do desenvolvimento, com equipamentos sem grande capacidades para processamento de algoritmos como os das CNNs os ajustes para o trabalho ficaram ainda mais lentos.

3.4 Redes neurais aplicadas ao processo de classificação

As redes neurais, em particular as redes neurais convolucionais (CNNs), têm se destacado na classificação de imagens devido à sua capacidade de aprender automaticamente características relevantes, tornando-as ideais para tarefas complexas como a análise de mamografias, para este trabalho os modelos foram construído em *python*, uma linguagem robusta e com uma crescente aplicação em

sistemas relacionados com IA. A arquitetura proposta inclui várias camadas convolucionais seguidas de camadas de *pooling*, que ajudam na extração de características e na redução da dimensionalidade das imagens.

O treinamento da rede foi realizado utilizando um conjunto de dados com aproximadamente 7 mil imagens onde foram separadas 6 mil para treinamento e 1 mil para teste, a *label* de identificação também foi usada, permitindo assim separar as imagens com e sem anomalias, com ajustes em hiperparâmetros como taxa de aprendizado e número de épocas para otimizar o desempenho. Além disso, foram aplicadas técnicas de aumento de dados, rotações das imagens, inversões e cortes aleatórios, para criar variações das imagens, aumentando a diversidade do conjunto de treinamento e melhorando a generalização do modelo.

O desempenho da rede será avaliado utilizando métricas como acurácia, precisão e *recall*, que fornecem uma visão abrangente da eficácia do modelo na classificação correta das mamografias. É crucial que as previsões feitas pela rede neural sejam interpretadas com cautela, e validações clínicas sejam realizadas para garantir que o modelo ofereça suporte confiável aos radiologistas.

3.4.1 Processo de treinamento e validação

Treinando a rede com os dados já tratados e as formas de configuração, apresentar também as formas dos dados que é esperado após a validação. Para treinamento dos modelos, antes será necessário o tratamento das imagens para o formato por ele suportado.

Em primeira instância foi identificado um possível problema com o desbalanceamento das imagens de casos negativos, o que levaria a resultados tendenciosos, uma solução poderia ser mudar a forma de divisão desse trabalho, adicionando mais uma etapa para teste, ao invés de usar a mesma de validação com esse propósito. O que, com o tempo curto não foi realizado neste trabalho, mas poderia ser aplicado em trabalhos futuros, para que assim o treinamento fosse realizado da maneira mais proveitosa possível.

Ao começar o trabalho a normalização das imagens foi a primeira etapa, depois foi identificado que o padrão para o *AlexNet* é 224x224 que seria também o mesmo para o *Resnet*, nesse ponto redimensionando todas as imagens para essa formatação. Com relação à escala de cor das imagens, estava em cinza, que apresenta apenas 1 canal, no entanto para trabalhar com esses modelos se fez

necessária a modificação para o padrão RGB, com 3 canais, foram então feitos esses ajustes.

Para o ajuste dos dados de treinamento e validação, foi determinada uma função responsável pelo controle desses parâmetros, ela vai ajudar a evitar o *sobreajuste* e na generalização dos modelos adicionando ainda zoom aleatório, rotação e cortes. A seguir será possível analisar alguns resultados de épocas enquanto estavam em treinamento para o *AlexNet* na tabela 1 e para o *ResNet* na tabela 2.

Tabela 1 - Métricas de desempenho do modelo AlexNet entre as épocas 12 a 18.

Épocas	Acurácia Treino	Perda Treino	Acurácia Validação	Perda Validação
12	0,7500	0,5732	0,6654	0,5701
13	0,6454	0,5719	0,6999	0,4899
14	0,5000	0,8393	0,6393	0,5537
15	0,6146	0,5627	0,6322	0,5770
16	0,6562	0,8223	0,5658	0,6495
17	0,5325	0,6202	0,6764	0,5181
18	0,6875	0,6565	0,6908	0,5058

Fonte: Elaborado pelo autor (2025).

A tabela 1 apresenta a evolução do desempenho do modelo *AlexNet* entre as épocas 12 e 18. A acurácia de validação manteve-se acima de 63% na maioria das épocas, com uma leve melhora nas últimas iterações. A perda de validação também caiu, indicando que o modelo está aprendendo de forma mais eficaz ao longo do tempo. Ainda que oscilações existam, especialmente na perda de treino, os resultados indicam potencial de generalização, com a última acurácia de validação alcançando 69,08%.

Tabela 2 - Métricas de desempenho do modelo *ResNet* entre as épocas 11 a 15.

Épocas	Acurácia Treino	Perda Treino	Acurácia Validação	Perda Validação
11	0,8595	0,4142	0,8717	0,3810
12	0,9062	0,3181	0,8717	0,3808
13	0,8760	0,3755	0,8717	0,3913
14	0,8125	0,4806	0,8717	0,3885
15	0,8692	0,3889	0,8717	0,3802

Fonte: Elaborado pelo autor (2025).

A tabela 2 apresenta os resultados de desempenho do modelo *ResNet* nesse intervalo de épocas. Observa-se uma estabilidade notável na acurácia de validação, que permaneceu em 87,17% em todas as épocas analisadas, demonstrando um bom poder de generalização do modelo. A acurácia de treinamento oscilou entre 81% e 90%, o que, aliado à baixa perda de validação, indica que o modelo não está sofrendo sobreajuste significativo neste ponto do treinamento. Esses resultados apontam para a robustez do modelo no contexto da classificação de imagens de mamografia.

Com tudo preparado e ajustado, o próximo passo foram os ajustes, treinamento e análise dos dados dos modelos.

3.4.2 Métricas de avaliação

Para avaliar o desempenho dos modelos *AlexNet* e *ResNet50* foram utilizadas métricas clássicas em tarefas de classificação supervisionada. Além disso, estratégias de preparação dos dados foram fundamentais para garantir a robustez dos resultados. A seguir, são descritos os principais elementos observados:

Acurácia: representa a proporção de acertos entre todas as classificações realizadas. Foi utilizada para indicar o desempenho geral do modelo em distinguir entre imagens com e sem indícios de câncer.

Perda: a função de perda foi usada durante o treinamento para medir o erro entre a saída prevista e o valor real. A redução contínua da perda ao longo das épocas foi um indicador de aprendizado eficaz.

Número de Épocas: o treinamento foi realizado com diferentes números de épocas, com o objetivo de encontrar um equilíbrio entre desempenho e tempo computacional. A variação da acurácia e da perda ao longo das épocas permitiu identificar o ponto ideal de parada para evitar tanto o sub-treinamento quanto o sobreajuste.

Comparação entre treinamento e teste: a diferença entre os acertos nos dados de treinamento e nos dados de teste foi analisada para detectar sinais de sobreajuste, situação em que o modelo aprende os dados de treino muito bem, mas perde capacidade de generalização.

Aumento de Dados (*Data Augmentation*): Para aumentar a diversidade do conjunto de treinamento e reduzir o risco de sobreajuste, foram aplicadas técnicas de aumento de dados, incluindo rotação, corte, ampliação e inversão aleatória das imagens. Essas transformações artificiais permitiram simular novas variações das mamografias, melhorando a capacidade dos modelos de reconhecer padrões visuais relevantes em diferentes condições.

O uso combinado dessas métricas e técnicas contribuiu significativamente para a avaliação e aprimoramento do desempenho dos modelos propostos neste trabalho e suas escolhas ainda reforçaram o nível de desbalanceamento do banco para imagens negativas, por isso o foco em métricas que analisassem os resultados para imagens positivas.

4 RESULTADOS E DISCUSSÕES

Após o treinamento dos modelos *AlexNet* e *ResNet50*, foram analisados os resultados obtidos com base nas métricas de avaliação mais comuns em tarefas de classificação de imagens: acurácia e perda. Durante os testes, o desempenho de cada modelo foi ajustado com diferentes configurações de número de épocas, taxa de dropout e técnicas de aumento de dados ou *data augmentation*, com o objetivo de reduzir o sobreajuste.

A Tabela 3 apresenta a estrutura do modelo *AlexNet* (de forma técnica) utilizado neste trabalho, evidenciando as camadas convolucionais, pooling e densas, bem como o número total de parâmetros treináveis. Nota-se que a complexidade do modelo contribui para sua capacidade de aprendizado, mas também requer cuidados com o sobreajuste, especialmente em bases de dados menores.

Tabela 3 - Estrutura das camadas do AlexNet

Camadas (Layer)	Saída (Output)	Parâmetros (Param #)
conv2d (Conv2D)	(None, 54, 54, 96)	34.944
max_pooling2d (MaxPooling2D)	(None, 26, 26, 96)	0
conv2d_1 (Conv2D)	(None, 26, 26, 256)	614.656
max_pooling2d_1 (MaxPooling2D)	(None, 12, 12, 256)	0
conv2d_2 (Conv2D)	(None, 12, 12, 384)	885.120
conv2d_3 (Conv2D)	(None, 12, 12, 384)	1.327.488
conv2d_4 (Conv2D)	(None, 12, 12, 256)	884.992
max_pooling2d_2 (MaxPooling2D)	(None, 5, 5, 256)	0
flatten (Flatten)	(None, 6400)	0
dense (Dense)	(None, 4096)	26.218.496
dropout (Dropout)	(None, 4096)	0
dense_1 (Dense)	(None, 4096)	16.781.312
dropout_1 (Dropout)	(None, 4096)	0
dense_2 (Dense)	(None, 1)	4.097

Fonte: *Elaborada pelo autor (2025).*

A seguir, a Tabela 4 apresenta a arquitetura do modelo *ResNet50* utilizado neste estudo, incluindo as camadas adicionais aplicadas ao final da base pré-treinada. O modelo foi adaptado para classificação binária (presença ou ausência de câncer), com camadas densas personalizadas para o ajuste à tarefa proposta.

Tabela 4 - Estrutura das camadas do ResNet

Camadas (<i>Layer</i>)	Saída (<i>Output</i>)	Parâmetros (Param #)
Resnet50 (Functional)	(None, 7, 7, 2048)	23.587.712
global_average_pooling2d (GlobalAveragePoolong2D)	(None, 2048)	0
dense (Dense)	(None, 1024)	2.098.176
dense_1 (Dense)	(None, 1)	1.025

Fonte: Elaborada pelo autor (2025).

Para o treinamento do modelo *ResNet50*, foi utilizada a abordagem de *transfer learning*, aproveitando a arquitetura da *ResNet50* com pesos pré-treinados no *ImageNet*. A camada superior original foi removida (*include_top=False*) e substituída por uma sequência composta por uma camada de pooling global, uma camada densa com 1024 neurônios e, por fim, uma camada de saída com ativação *sigmoid*, apropriada para classificação binária. As camadas do modelo base foram mantidas congeladas durante o treinamento, a fim de preservar os pesos previamente ajustados, o que é recomendável quando se trabalha com bases de dados limitadas.

O pré-processamento das imagens foi realizado com a função nativa da *ResNet50*, garantindo compatibilidade com os pesos originais. Além disso, foi aplicada uma estratégia de aumento de dados (*data augmentation*), incluindo rotação, deslocamentos horizontais e verticais, zoom, inversão horizontal e transformações geométricas, visando aumentar a diversidade das imagens de treino e reduzir o risco de sobreajuste. As imagens foram redimensionadas para 224x224 *pixels* e processadas em lotes de 32.

O treinamento foi conduzido por 15 épocas inicialmente, mas ajustado quando necessário, com o otimizador Adam e função de perda binary *crossentropy*. A avaliação do modelo foi realizada com base na acurácia e perda, tanto no conjunto de treino quanto no conjunto de validação, conforme apresentado na seção de resultados.

Além da acurácia, foram calculadas as métricas de sensibilidade e especificidade, fundamentais em cenários de diagnóstico médico. A sensibilidade mede a capacidade do modelo de identificar corretamente casos positivos (ex: câncer), enquanto a especificidade indica a precisão ao reconhecer casos negativos. Essas métricas foram extraídas a partir da matriz de confusão gerada com base nas previsões sobre o conjunto de validação.


Para o modelo baseado na arquitetura *AlexNet*, foi implementado do zero, contendo cinco camadas convolucionais seguidas de três camadas densas (*fully connected*), com funções de ativação *ReLU* e camadas de pooling para redução da dimensionalidade. Foi aplicada a função de ativação *sigmoid* na camada de saída, adequada para o problema de classificação binária.

Os dados de entrada foram redimensionados para 224×224 *pixels*, com o auxílio da ferramenta *ImageDataGenerator*, que também realizou técnicas de aumento de dados como rotações, deslocamentos, zoom e inversão horizontal. O conjunto de dados foi dividido em dois grupos: treino e validação, e o modelo foi treinado por 30 épocas. Na tabela 5 a seguir, é possível analisar a matriz de confusão e no gráfico 3 os dados sobre o desempenho do *AlexNet*.

Tabela 5 - Matriz de confusão do *AlexNet*

	Predito: negativo	Predito: positivo
Real negativo	1301	20
Real positivo	190	26

Fonte: Elaborada pelo autor (2025).

Gráfico 3 - Métricas de desempenho do *AlexNet*

Fonte: Elaborado pelo autor (2025).

Com essas tabelas é possível comparar os resultados desse outro teste para o modelo *AlexNet*, é bem perceptível que algumas alterações como o aumento ou diminuição do *dropout*, número de épocas, ou qualquer ajuste nos atributos da função responsável pelo aumento de dados mudam os resultados do modelo.


Na tabela 6 é possível analisar os resultados da matriz de confusão e na gráfico 4 as métricas de desempenho, quando o números de épocas foi aumentado para 50 e uma condição automática foi adicionada.

Tabela 6 - Matriz de confusão do *AlexNet* quando foram rodadas 18 épocas de 50.

	Predito: negativo	Predito: positivo
Real negativo	688	633
Real positivo	22	194

Fonte: Elaborada pelo autor (2025).

Gráfico 4 - Métricas de desempenho do *AlexNet* quando foram rodadas 18 épocas de 50.



Fonte: Elaborado pelo autor (2025).


Após o treinamento, além das métricas tradicionais de acurácia e perda, foram também calculadas a sensibilidade ou *recall* e a especificidade, a partir da matriz de confusão gerada com as previsões. A sensibilidade mede a capacidade do modelo de identificar corretamente casos positivos nas imagens de mamografias, enquanto a especificidade avalia a taxa de identificação correta de casos negativos.

A Tabela 7 a seguir, apresenta a matriz de confusão gerada pelo modelo *ResNet* no conjunto de testes. Observa-se que o modelo teve alta capacidade de identificar corretamente os casos negativos com 1293, refletindo em alta especificidade (96,56%). No entanto, apresentou baixa sensibilidade (26,77%), indicando que teve dificuldade em identificar corretamente todos os casos positivos com 53.

Tabela 7 - Matriz de confusão do *ResNet*

	Predito: negativo	Predito: positivo
Real negativo	1293	46
Real positivo	145	53

Fonte: *Elaborada pelo autor (2025).*

Gráfico 5 - Métricas de desempenho do *ResNet*

Fonte: *Elaborado pelo autor (2025).*

O gráfico 5 mostra as principais métricas de desempenho. Embora a acurácia geral seja de 88%, o modelo ainda tende a ser mais conservador, priorizando a classificação negativa, o que é comum em bases desbalanceadas.

Apesar dos bons resultados, o tempo limitado impediu a aplicação de testes com outros conjuntos de dados, o que seria relevante para avaliar a capacidade de generalização dos modelos em diferentes cenários. Esse ponto é sugerido como continuidade para futuros trabalhos, assim como os outros pontos já apontados anteriormente, como o ajuste aos casos positivos e aumento dos dados de forma total.

5 CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi demonstrar como redes neurais convolucionais (CNNs) podem ser utilizadas na análise de imagens de mamografias (MMGs), evidenciando o potencial desses algoritmos em aplicações práticas na área da saúde. Além de destacar a evolução tecnológica, o estudo mostrou que tais ferramentas podem contribuir de forma significativa para o diagnóstico precoce e a eficiência clínica.

A combinação entre tecnologia e saúde apresenta um grande potencial transformador. Sistemas baseados em inteligência artificial são capazes de processar e interpretar grandes volumes de dados em tempo reduzido, otimizando diagnósticos e reduzindo atrasos em tratamentos. Este trabalho evidenciou essa capacidade por meio da implementação de modelos treinados para identificar padrões em mamografias.

Durante a pesquisa, foram aplicados modelos baseados nas arquiteturas *AlexNet* e *ResNet*, treinados com um conjunto de dados balanceados e submetidos a testes rigorosos. Ambos os modelos demonstraram desempenhos relevantes, com acurácias médias superiores a 80%, mesmo com limitações no volume de dados e tempo de treinamento.

O modelo *AlexNet* apresentou uma acurácia de 96,88% no conjunto de treinamento, mas com uma leve queda para cerca de 86% nos conjuntos de validação e teste, indicando um leve sobreajuste. Apesar disso, a proximidade entre os resultados de validação e teste demonstrou uma boa capacidade de generalização, tornando-o promissor como ferramenta de apoio ao diagnóstico.

Por outro lado, o modelo *ResNet*, embora com acurácia de treinamento inferior, mostrou-se mais robusto e estável, com desempenho mais consistente nos conjuntos de validação e teste. Essa característica reforça sua capacidade de generalização e o torna particularmente adequado para cenários clínicos, onde a confiabilidade fora dos dados de treinamento é essencial.

Com os resultados obtidos, fica evidente que a *ResNet* demonstrou superioridade em termos de robustez e desempenho geral, alinhando-se às expectativas teóricas de sua arquitetura mais profunda e avançada.

Conclui-se que o uso de inteligência artificial para análise de imagens médicas é viável e promissor. Apesar das limitações enfrentadas neste estudo (como o volume restrito de dados e o tempo de processamento), os resultados alcançados foram expressivos e apontam para o potencial dessa abordagem como ferramenta complementar no diagnóstico precoce do câncer de mama. Estudos futuros poderão explorar conjuntos de dados maiores e modelos mais avançados, buscando aperfeiçoar ainda mais o desempenho e a aplicabilidade desses sistemas na prática clínica.

REFERÊNCIA

BRITO, E. N. D. et al. **Inteligência artificial no diagnóstico de doenças neurodegenerativas: uma revisão sistemática de literatura.** *Research, Society and Development*, v. 10, n. 11, 2021.

CAMPOS, R. S. **Desmistificando a inteligência artificial: Uma breve introdução conceitual ao aprendizado de máquina.** *Aoristo-International Journal of Phenomenology, Hermeneutics and Metaphysics*, v. 3, n. 1, p. 106–123, 2020.

Câncer de Mama Brasil. **Como Funciona a Ressonância Magnética das Mamas.** 2024. Disponível em: <https://www.cancerdemamabrasil.com.br/como-funciona-a-ressonancia-magnetica-das-mamas>. Acesso em: 09 set. 2024.

Conselho Federal de Medicina. **CFM inicia pesquisa sobre o uso de inteligência artificial na medicina.** 2023. Disponível em: <https://portal.cfm.org.br/noticias/cfm-inicia-pesquisa-sobre-o-uso-de-inteligencia-artificial-na-medicina>. Acesso em: 17 set. 2024.

Conselho Nacional de Saúde. **Câncer de Mama: Prevenção, Detecção Precoce e Redução de Riscos Evitáveis Estão Entre as Estratégias para Diminuir Mortalidade.** 2024. Disponível em: <https://conselho.saude.gov.br/ultimas-noticias-cns/3193-cancer-de-mama-prevencao-deteccao-precoce-e-reducao-de-riscos-evitaveis-estao-entre-as-estrategias-para-diminuir-mortalidade>. Acesso em: 19 set. 2024.

Dasa. **Ultrassom da Mama: Entenda a Importância e Como é Feito.** 2024. Disponível em: <https://nav.dasa.com.br/blog/ultrassom-da-mama>. Acesso em: 09 set. 2024.

DataCamp. **YOLO Object Detection Explained.** 2024. Disponível em: <https://www.datacamp.com/pt/blog/yolo-object-detection-explained>. Acesso em: 08 ago. 2024.

FDG Cirurgia Plástica. **Outubro Rosa: Aprenda a Fazer o Autoexame**. 2024. Disponível em: <https://fdgcirurgiaplastica.com.br/outubro-rosa-aprenda-a-fazer-o-autoexame/>. Acesso em: 09 set. 2024.

Kaggle User. **DDSM Mammography Dataset**. 2024. Disponível em: <https://www.kaggle.com/datasets/skooch/ddsm-mammography>. Acesso em: 10 set. 2024.

INSTITUTO NACIONAL DE CÂNCER (INCA). **Câncer de Mama**. 2024. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/mama>. Acesso em: 22 ago. 2024.

INSTITUTO NACIONAL DE CÂNCER (INCA). **Mortalidade por Câncer de Mama**. 2024. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-cancer-de-mama/dados-e-numeros/mortalidade>. Acesso em: 19 set. 2024.

INSTITUTO NACIONAL DE CÂNCER (INCA). **Tratamento do Câncer de Mama**. 2024. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-cancer-de-mama/acoes/tratamento>. Acesso em: 16 set. 2024.

MACHADO, M. d. S. **Inteligência Artificial no Auxílio do Diagnóstico Precoce do Câncer de Mama**. Dissertação (B.S. thesis) — UFPE, 2024.

Medicina SA. **Termografia: Detecção de Câncer**. 2024. Disponível em: <https://medicinasa.com.br/termografia-deteccao-cancer/>. Acesso em: 09 set. 2024.

NGX, Tommy. **Inbreast 2012**. [S.l.], 2012. Disponível em: <https://www.kaggle.com/datasets/tommyngx/inbreast2012>. Acesso em: 28 nov. 2024.

Ó, F. F. R. D. **Inteligência artificial aplicada à análise de imagens médicas em ensaios clínicos sobre câncer**. Dissertação (B.S. thesis) — Universidade Federal do Rio Grande do Norte, 2023.

Observatório da APS. **Câncer de mama: dados da doença, tratamento e detecção precoce.** 2024. Disponível em: <https://biblioteca.observatoriodaaps.com.br/blog/cancer-de-mama-dados-da-doenca-tratamento-e-deteccao-precoce/>.

SILVA, A. F. d. **Sistema inteligente para o apoio ao diagnóstico do câncer de mama usando imagens termográficas e redes neurais artificiais profundas.** Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2022.

Star Med. **BI-RADS: Classificação - O que é?** 2024. Disponível em: <https://star.med.br/bi-rads-classificacao-o-que-e/>. Acesso em: 01 set. 2024.

SÉRGIO FRANCO. **BRCA1 e BRCA2: Entenda a relação da mutação com o câncer de mama.** 2023. Disponível em: <https://sergiofranco.com.br/saude/exame-brca1-e-brca2>. Acesso em: 9 set. 2024.

TRAN THI PHUONG NGAN. **Mamogram Dataset.** 2024. Disponível em: <https://www.kaggle.com/datasets/tranthiphuongngan/mamogram-dataset>. Acesso em: 19 set. 2024.

TRICKS, C. **Understand ResNet, AlexNet, VGG, and Inception.** 2017. Disponível em: <https://cv-tricks.com/cnn/understand-resnet-alexnet-vgg-inception/>. Acesso em: 19 set. 2024.

VIEZZER, M. **O uso da inteligência artificial pelo sistema jurídico brasileiro, classificação da inteligência artificial e análise de seu uso.** *Revista Ibero-Americana de Humanidades, Ciências e Educação*, v. 8, n. 1, p. 1193–1213, 2022. Acesso em: 22 set. 2024.

ZEEV. **O que é Inteligência Artificial?** 2024. Disponível em: <https://zeev.it/blog/o-que-e-inteligencia-artificial/>. Acesso em: 19 set. 2024.

APÊNDICE

Apêndice A - Código desenvolvido para o modelo AlexNet

O código construído para esse trabalho mostrou como a estrutura do AlexNet era arcaica em relação ao Resnet.

```
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras import layers, models
from sklearn.utils import class_weight
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
from sklearn.metrics import confusion_matrix, classification_report
import numpy as np

train_dir = '/modelos/alexnet_images/train'
test_dir = '/modelos/alexnet_images/test'

train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=10,
    width_shift_range=0.3,
    height_shift_range=0.3,
    shear_range=0.3,
    zoom_range=0.3,
    horizontal_flip=True,
    fill_mode='nearest'
)

test_datagen = ImageDataGenerator(rescale=1./255)

train_generator = train_datagen.flow_from_directory(
    train_dir,
    target_size=(224, 224),
    batch_size=32,
    class_mode='binary',
    shuffle=True
)

validation_generator = test_datagen.flow_from_directory(
    test_dir,
    target_size=(224, 224),
    batch_size=32,
```

```

        class_mode='binary',
        shuffle=False
    )

    print(f'Número de imagens de treino: {train_generator.samples}')
    print(f'Número de imagens de validação:
    {validation_generator.samples}')

    model = models.Sequential([
        layers.Conv2D(96, (11, 11), strides=(4, 4), activation='relu',
input_shape=(224, 224, 3)),
        layers.MaxPooling2D((3, 3), strides=(2, 2)),
        layers.Conv2D(256, (5, 5), activation='relu', padding='same'),
        layers.MaxPooling2D((3, 3), strides=(2, 2)),
        layers.Conv2D(384, (3, 3), activation='relu', padding='same'),
        layers.Conv2D(384, (3, 3), activation='relu', padding='same'),
        layers.Conv2D(256, (3, 3), activation='relu', padding='same'),
        layers.MaxPooling2D((3, 3), strides=(2, 2)),
        layers.Flatten(),
        layers.Dense(4096, activation='relu'),
        layers.Dropout(0.3),
        layers.Dense(4096, activation='relu'),
        layers.Dropout(0.3),
        layers.Dense(1, activation='sigmoid')
    ])

    model.compile(optimizer='adam', loss='binary_crossentropy',
metrics=['accuracy'])
    model.summary()

    class_weights = class_weight.compute_class_weight(
        class_weight='balanced',
        classes=np.unique(train_generator.classes),
        y=train_generator.classes
    )

    class_weights = dict(enumerate(class_weights))

    checkpoint = ModelCheckpoint(
        'melhor_modelo_AlexNet.h5',
        monitor='val_loss',
        save_best_only=True,
        save_weights_only=False,

```

```

        mode='min',
        verbose=1
    )

    early_stop = EarlyStopping(
        monitor='val_loss',
        patience=5,
        restore_best_weights=True
    )

    history = model.fit(
        train_generator,
        epochs=50,
        validation_data=validation_generator,
        class_weight=class_weights,
        callbacks=[early_stop, checkpoint]
    )

    print(f"Acurácia de Treinamento: {history.history['accuracy'][-1]:.4f}")
    print(f"Perda de Treinamento: {history.history['loss'][-1]:.4f}")
    print(f"Acurácia de Validação: {history.history['val_accuracy'][-1]:.4f}")
    print(f"Perda de Validação: {history.history['val_loss'][-1]:.4f}")

    test_loss, test_acc = model.evaluate(validation_generator)
    print(f"\nPerda de Teste: {test_loss:.4f}")
    print(f"Acurácia de Teste: {test_acc:.4f}")

    pred_probs = model.predict(validation_generator,
                               steps=validation_generator.samples // validation_generator.batch_size + 1)
    preds = (pred_probs > 0.6).astype(int).flatten()
    true_labels = validation_generator.classes

    cm = confusion_matrix(true_labels, preds)
    tn, fp, fn, tp = cm.ravel()

    sensibilidade = tp / (tp + fn) if (tp + fn) > 0 else 0
    especificidade = tn / (tn + fp) if (tn + fp) > 0 else 0

    print(f"\nMatriz de Confusão:\n{cm}")
    print(f"Sensibilidade (Recall): {sensibilidade:.4f}")

```

```
print(f"Especificidade: {especificidade:.4f}")

print("\nRelatório de Classificação:")
print(classification_report(true_labels, preds,
target_names=['Negativo', 'Positivo']))
```

Apêndice B - Código desenvolvido para o modelo ResNet

O código para este modelo já tem uma estrutura mais robusta e notável.

```
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras import applications, layers, models, optimizers
from sklearn.utils import class_weight
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
from sklearn.metrics import confusion_matrix, classification_report
import numpy as np

train_dir = '/modelos/resnet_images/train'
test_dir = '/modelos/resnet_images/test'

train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=15,
    width_shift_range=0.2,
    height_shift_range=0.2,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode='nearest',

    preprocessing_function=tf.keras.applications.resnet50.preprocess_input
)

test_datagen = ImageDataGenerator(
    rescale=1./255,

    preprocessing_function=tf.keras.applications.resnet50.preprocess_input
)

train_generator = train_datagen.flow_from_directory(
    train_dir,
    target_size=(224, 224),
    batch_size=32,
    class_mode='binary',
    shuffle=True
)

validation_generator = test_datagen.flow_from_directory(
    test_dir,
```

```

        target_size=(224, 224),
        batch_size=32,
        class_mode='binary',
        shuffle=False
    )

print(f'Número de imagens de treino: {train_generator.samples}')
print(f'Número de imagens de validação:
{validation_generator.samples}')

base_model = applications.ResNet50(weights='imagenet',
include_top=False, input_shape=(224, 224, 3))

base_model.trainable = True
for layer in base_model.layers[:-10]:
    layer.trainable = False

model = models.Sequential([
    base_model,
    layers.GlobalAveragePooling2D(),
    layers.Dense(512, activation='relu'),
    layers.Dropout(0.5),
    layers.Dense(1, activation='sigmoid')
])

optimizer = optimizers.Adam(learning_rate=1e-5)

model.compile(optimizer=optimizer, loss='binary_crossentropy',
metrics=['accuracy'])
model.summary()

class_weights = class_weight.compute_class_weight(
    class_weight='balanced',
    classes=np.unique(train_generator.classes),
    y=train_generator.classes
)

class_weights = dict(enumerate(class_weights))

early_stop = EarlyStopping(monitor='val_loss', patience=5,
restore_best_weights=True)

checkpoint = ModelCheckpoint(
    'melhor_modelo_ResNet.h5',

```

```

        monitor='val_loss',
        save_best_only=True,
        save_weights_only=False,
        mode='min',
        verbose=1
    )
history = model.fit(
    train_generator,
    epochs=30,
    validation_data=validation_generator,
    class_weight=class_weights,
    callbacks=[early_stop, checkpoint]
)
print(f"\nAcurácia de Treinamento:
{history.history['accuracy'][-1]:.4f}")
print(f"Perda de Treinamento: {history.history['loss'][-1]:.4f}")
print(f"Acurácia de Validação:
{history.history['val_accuracy'][-1]:.4f}")
print(f"Perda de Validação: {history.history['val_loss'][-1]:.4f}")

test_loss, test_accuracy = model.evaluate(validation_generator)
print(f"\nPerda no Teste: {test_loss:.4f}")
print(f"Acurácia no Teste: {test_accuracy:.4f}")

pred_probs = model.predict(validation_generator,
steps=validation_generator.samples // validation_generator.batch_size +
1)
preds = (pred_probs > 0.6).astype(int).flatten()
true_labels = validation_generator.classes[:len(preds)]

cm = confusion_matrix(true_labels, preds)
tn, fp, fn, tp = cm.ravel()

sensibilidade = tp / (tp + fn) if (tp + fn) > 0 else 0
especificidade = tn / (tn + fp) if (tn + fp) > 0 else 0

print(f"\nMatriz de Confusão:\n{cm}")
print(f"Sensibilidade (Recall): {sensibilidade:.4f}")
print(f"Especificidade: {especificidade:.4f}")
print("\nRelatório de Classificação:")
print(classification_report(true_labels, preds,
target_names=['Negativo', 'Positivo']))

```

Apêndice C - Código desenvolvido para extração das imagens do *dataset*

O código apresenta a estruturação das pastas para treino e teste usadas nos modelos.

```
import numpy as np
import os
from PIL import Image
import random
import matplotlib.pyplot as plt

def inspect_and_save_npy_files_resnet(labels_file, images_file,
output_folder, target_size=(224, 224), train_ratio=0.8,
display_examples=5):
    annotations = np.load(labels_file, allow_pickle=True)
    images = np.load(images_file, allow_pickle=True)

    print(f"Número de rótulos: {len(annotations)}")
    print(f"Número de imagens: {len(images)}")

    os.makedirs(output_folder, exist_ok=True)

    train_folder = os.path.join(output_folder, 'train')
    test_folder = os.path.join(output_folder, 'test')
    os.makedirs(train_folder, exist_ok=True)
    os.makedirs(test_folder, exist_ok=True)

    class_0_train = os.path.join(train_folder, '0')
    class_1_train = os.path.join(train_folder, '1')
    class_0_test = os.path.join(test_folder, '0')
    class_1_test = os.path.join(test_folder, '1')
    os.makedirs(class_0_train, exist_ok=True)
    os.makedirs(class_1_train, exist_ok=True)
    os.makedirs(class_0_test, exist_ok=True)
    os.makedirs(class_1_test, exist_ok=True)

    indices = list(range(len(annotations)))
    random.shuffle(indices)

    train_size = int(len(indices) * train_ratio)
    train_indices = indices[:train_size]
    test_indices = indices[train_size:]

    def save_images(indices, folder):
```

```

    for i in indices:
        img_array = images[i]

        if img_array.ndim == 3 and img_array.shape[2] == 1:
            img_array = np.repeat(img_array, 3, axis=-1)

        img_array = img_array.astype(np.float32) / 255.0

        img_array = np.array(Image.fromarray((img_array *
255).astype(np.uint8)).resize(target_size))

        img = Image.fromarray(img_array.astype(np.uint8))

        label = annotations[i]
        if label == 0:
            image_path = os.path.join(folder, '0',
f'image_{i}.jpg')
        else:
            image_path = os.path.join(folder, '1',
f'image_{i}.jpg')

        img.save(image_path)

    save_images(train_indices, train_folder)
    save_images(test_indices, test_folder)

    if display_examples > 0:
        for i in random.sample(train_indices, display_examples):
            img_array = images[i]
            if img_array.ndim == 3 and img_array.shape[2] == 1:
                img_array = np.repeat(img_array, 3, axis=-1)
            img_array = img_array.astype(np.float32) / 255.0
            img_array = np.array(Image.fromarray((img_array *
255).astype(np.uint8)).resize(target_size))
            plt.imshow(img_array)
            plt.title(f"Rótulo: {annotations[i]}")
            plt.axis('off')
            plt.show()

    print(f'{len(annotations)} imagens extraídas e salvas em:
{output_folder}')
    print(f'{len(train_indices)} imagens para treinamento e
{len(test_indices)} imagens para teste')

```

```
labels_file = '/kaggle/input/ddsm-mammography/cv10_labels.npy'  
images_file = '/kaggle/input/ddsm-mammography/cv10_data/cv10_data.npy'  
output_folder = '/kaggle/working/resnet_images'  
  
inspect_and_save_npy_files_resnet(labels_file, images_file,  
output_folder)
```