

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Adib Cecilio Prado Domingos

**Redes Neurais Convolucionais para detecção de
câncer de mama utilizando regiões de interesse
de imagens infravermelhas**

Uberlândia, Brasil

2021

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Adib Cecilio Prado Domingos

**Redes Neurais Convolucionais para detecção de câncer
de mama utilizando regiões de interesse de imagens
infravermelhas**

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, como parte dos requisitos exigidos para a obtenção título de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Henrique Coelho Fernandes

Universidade Federal de Uberlândia – UFU

Faculdade de Computação

Bacharelado em Ciência da Computação

Uberlândia, Brasil

2021

Adib Cecilio Prado Domingos

Redes Neurais Convolucionais para detecção de câncer de mama utilizando regiões de interesse de imagens infravermelhas

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, como parte dos requisitos exigidos para a obtenção título de Bacharel em Ciência da Computação.

Trabalho aprovado. Uberlândia, Brasil, 01 de novembro de 2021.

Prof. Dr. Henrique Coelho Fernandes
Orientador

Prof. Dr. Paulo Henrique Ribeiro
Gabriel

Prof. Dr. Bruno Augusto Nassif
Travençolo

Uberlândia, Brasil
2021

Resumo

O câncer de mama é o tipo mais comum de câncer entre as mulheres no Brasil e no mundo. A incidência em mulheres jovens vem aumentando ao longo dos anos e o exame padrão ouro para diagnóstico, que é a mamografia, é contraindicado para menores de 40 anos. A termografia surge nesse cenário como uma técnica promissora para detecção precoce e maior taxa de sobrevivência desse grupo de mulheres. A análise de imagens termográficas por Redes Neurais Convolucionais tem bons resultados no sentido de aumentar a confiabilidade e a sensibilidade de diagnósticos. Esse trabalho utiliza as redes Densenet201 e Resnet50 em uma base de 72 imagens de pacientes distintas, sendo 38 doentes e 38 saudáveis. Essas imagens passaram por um pré-processamento antes de serem analisadas, sendo que em uma das etapas de pré-processamento houve um recorte manual apenas da região de interesse das mamas, com o objetivo de avaliar se há uma superioridade de detecção em relação as imagens inteiras. A melhor média de taxa de precisão foi obtida com a rede Densenet201, taxa de aprendizagem de 0.001 e 30 épocas, que chegou a 89%. Já em relação ao f1-score, a rede com melhor desempenho foi a Resnet50, taxa de aprendizagem de 0.0001 e 30 épocas, que chegou a 76%.

Palavras-chave: Câncer de mama, Inteligência Artificial, Redes Neurais, Densenet, Resnet, Termografia Infravermelha

Lista de ilustrações

Figura 1 – Prisma	8
Figura 2 – Câmera termográfica	9
Figura 3 – Espectro Eletromagnético	10
Figura 4 – Imagem Resnet	11
Figura 5 – Imagem Densenet	12
Figura 6 – Fórmula de sensibilidade	13
Figura 7 – Fórmula de especificidade	13
Figura 8 – Fórmula de acurácia	13
Figura 9 – Fórmula de precisão	13
Figura 10 – Fórmula de f1-score	14
Figura 11 – Confusion Matrix	14
Figura 12 – Fluxograma do estudo	17
Figura 13 – Paciente Saudável	19
Figura 14 – Paciente com neoplasia mamária	20
Figura 15 – Imagem térmica original	21
Figura 16 – Imagem térmica normalizada	22
Figura 17 – Imagem da região de interesse normalizada	23
Figura 18 – Imagem da região de interesse normalizada e reduzida	24
Figura 19 – Imagem colorida	24
Figura 20 – Matriz de confusão do melhor resultado Densenet 201	27
Figura 21 – Matriz de confusão do melhor resultado Resnet 50	28

Sumário

1	INTRODUÇÃO	6
1.1	Justificativa	7
1.2	Objetivo	7
2	REFERENCIAL TEÓRICO	8
2.1	Imagens Infravermelhas	8
2.2	Redes Neurais Convolucionais (CNN)	10
2.2.1	Resnet 50	11
2.2.2	Densenet 201	11
2.2.3	Métricas de avaliação	12
3	REVISAO BIBLIOGRÁFICA	15
3.1	Trabalhos correlatos	15
4	METODOLOGIA	17
4.1	Banco de Dados	17
4.2	Pré-processamento	21
4.2.1	1ª Etapa - Normalização	21
4.2.2	2ª Etapa - Recorte	22
4.2.3	3ª Etapa - Redução dos Pixels	23
4.2.4	4ª Etapa - Coloração	24
4.3	Classificação	25
5	RESULTADOS E DISCUSSÕES	26
6	CONCLUSÃO	29
	REFERÊNCIAS	30

1 Introdução

A neoplasia mamária é o tipo de câncer mais comum entre as mulheres não só no Brasil, mas no mundo todo (CANCER, 2018). Apesar da incidência ser maior entre as mulheres maiores de 50 anos, os casos em mulheres mais jovens têm aumentado progressivamente nos últimos anos (BORCHARTT et al., 2013).

O diagnóstico precoce é muito importante, pois a chance de cura do câncer de mama cai drasticamente se a doença não for descoberta nos estágios iniciais (LESSA; MARENGONI, 2016). Atualmente existem diversos exames por imagem que são utilizados para a triagem ou auxílio no diagnóstico complementar desse tipo de neoplasia, sendo a mamografia o mais comum deles.

A mamografia é um exame preconizado pelo SUS (Sistema Único de Saúde) para mulheres somente a partir de 40 anos, devido ao fato de a radiação ionizante utilizada no exame ser considerada um fator de risco para o câncer de mama em mulheres mais jovens. Apesar de ter uma sensibilidade em torno de 85%, esse exame é influenciado por algumas variáveis, como a idade da mulher e a densidade de suas mamas. Isso porque quanto mais novas são as mulheres, mais densas são suas mamas e a análise visual diferencial da mamografia de uma mama densa é mais suscetível a enganos (BEZERRA, 2007).

Recentemente, uma técnica não-invasiva, sem contato, de baixo custo, rápida, indolor e de alta sensibilidade tem ganhado atenção. Essa técnica pode ser utilizada para mulheres de todas as idades, com qualquer tamanho de mama e densidade, para as mulheres jovens e grávidas. Trata-se da termografia, que se baseia no princípio de que a atividade metabólica e a circulação vascular nos tecidos cancerosos e na área em torno de um desenvolvimento de tumor da mama são quase sempre maiores do que no tecido mamário normal. (MILOEVIĆ; JANKOVIC; PEULIC, 2014)

Na termografia, por meio da radiação infravermelha, uma câmera especializada é capaz de detectar o calor que chega do interior do tecido até a superfície da pele através da condução térmica. Esse calor é ilustrado na forma de um gráfico com um gradiente de cores, de modo que a região onde do câncer fica com coloração que representa maior temperatura (LELES, 2015). Esse procedimento é chamado de termografia infravermelha (TIR).

A TIR para detecção de câncer de mama tem seus primeiros relatos de utilização na década de 50. No entanto, os resultados obtidos naquela época não eram satisfatórios devido à limitação tecnológica. Mas a partir dos anos 2000, com a melhoria das câmeras infravermelhas e o avanço da inteligência artificial (IA), a termografia infravermelha tem se mostrado uma técnica promissora para detecção do câncer de mama. (KANDLIKAR et

al., 2017)

Nesse sentido, este trabalho estudará o uso de técnicas de IA combinadas com imagens infravermelhas para a detecção de câncer de mama. As Redes Neurais avaliadas foram a Densenet201 e a Resnet50. A melhor média de taxa de precisão foi obtida com a rede Densenet201, taxa de aprendizagem de 0.001 e 30 épocas, que chegou a 89%. Já em relação ao f1-score, a rede com melhor desempenho foi a Resnet50, taxa de aprendizagem de 0.0001 e 30 épocas, que chegou a 76%.

1.1 Justificativa

Apesar de atraentes, os diagnósticos de câncer de mama utilizando somente imagens termográficas ainda não são totalmente aceitos pela comunidade médica, sendo utilizados como exames complementares. Todavia, diante do crescente aumento dos casos de neoplasia mamária em mulheres mais jovens e das limitações da mamografia nesse tipo de público, é de extrema importância ressignificar essa concepção médica.

Várias técnicas de análise de imagens podem ser usadas com o intuito de aumentar a confiabilidade e a sensibilidade desses diagnósticos, sendo que as que possuem melhores resultados são as baseadas em Redes Neurais Convolucionais (do inglês CNN). Sendo assim, esse trabalho propõe um sistema inteligente de detecção de câncer de mama, baseado na análise de imagens termográficas e algoritmos de CNN, em que os resultados indicarão o potencial desta abordagem em substituir exames convencionais, como a mamografia.

1.2 Objetivo

Comparar o desempenho de diferentes CNNs diante das métricas F1-Score e precisão em imagens inteiras e imagens somente da região de interesse para detecção de câncer de mama e avaliar se há uma superioridade de detecção nas imagens somente da região de interesse.

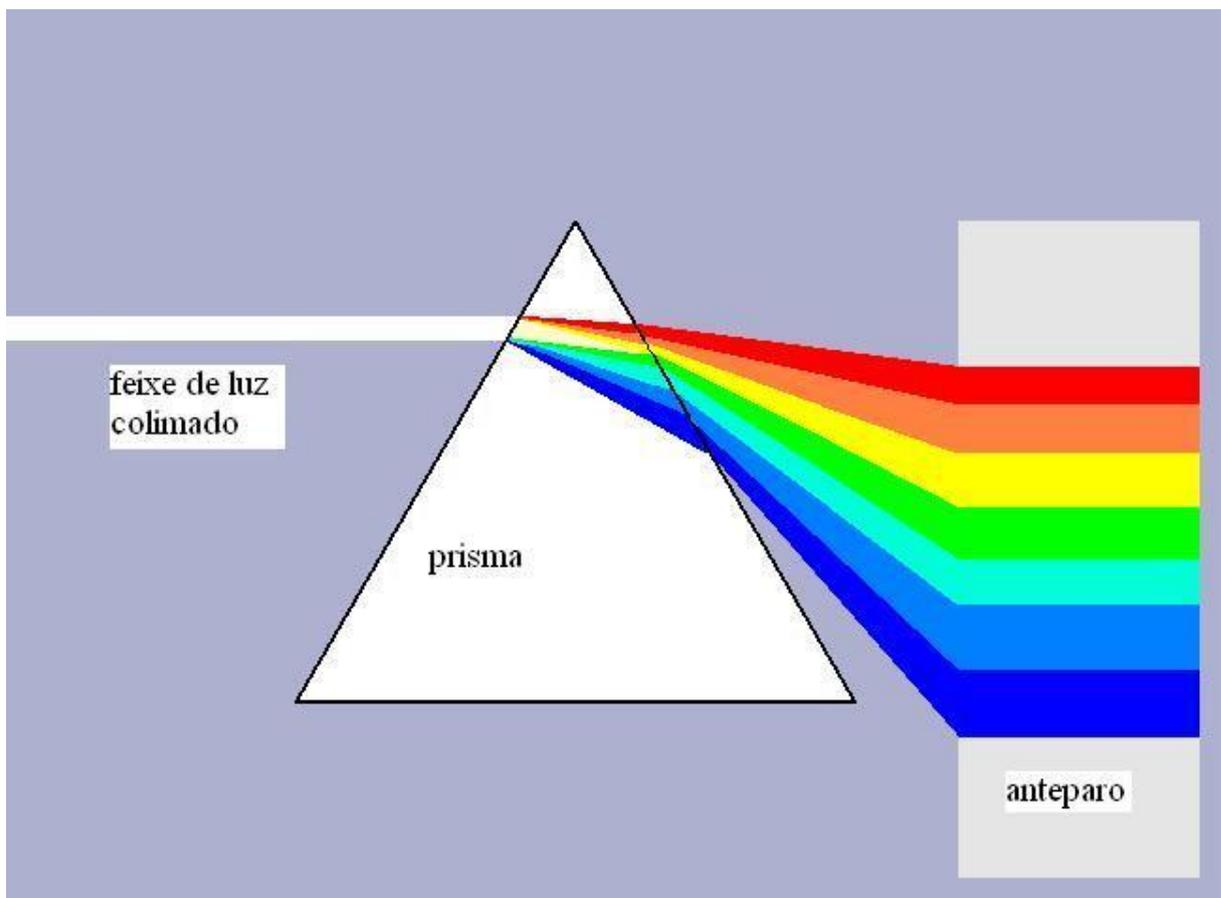
2 Referencial teórico

Para o entendimento deste trabalho, o conhecimento de alguns conceitos e definições se faz necessário. Os mesmos serão apresentados neste capítulo.

2.1 Imagens Infravermelhas

A radiação infravermelha foi descoberta pelos estudos desenvolvidos pelo astrônomo Willian Herschel. Após repetir o experimento feito por Isaac Newton ao dispersar a luz solar com a ajuda de um prisma (Figura 1), Herschel procurava a cor que possui maior temperatura incidindo os feixes sobre um termômetro. Foi quando ele percebeu que a região de frequência um pouco menor que a da luz vermelha era a região mais quente (JUNIOR, 2021).

Figura 1 – Exemplo da ação de um prisma



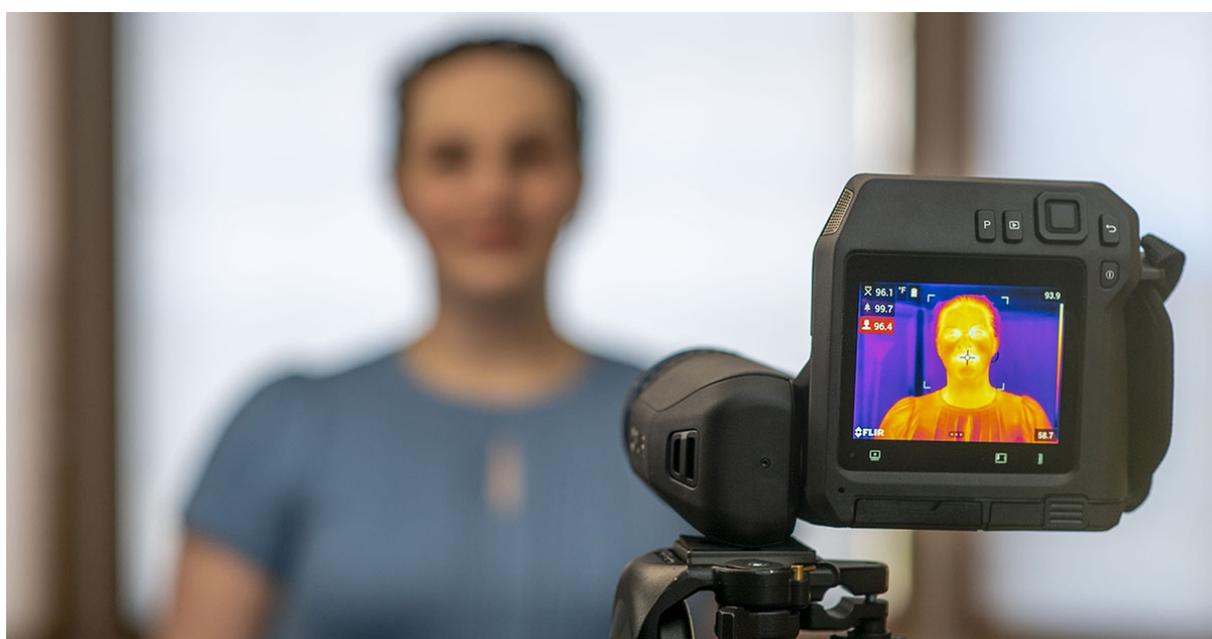
(KITOR, 2021)

O nome infravermelho origina-se justamente do fato de a frequência da radiação

ser menor que a frequência da luz vermelha, a qual, por sua vez, é a menor frequência captada pelo olho humano. (JUNIOR, 2021)

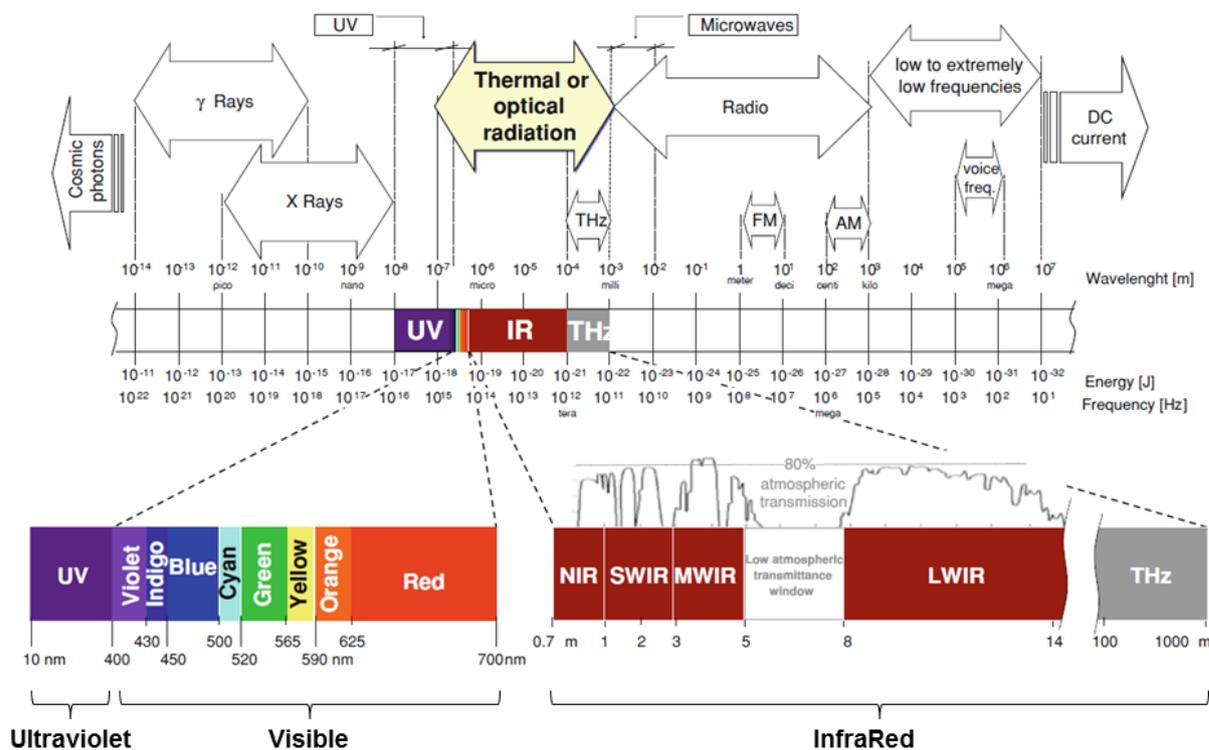
O princípio utilizado pela termografia é de que todo corpo com temperatura acima do zero absoluto emite radiação infravermelha. (NG, 2009) Na medicina, quando células apresentam anomalias, há alterações no metabolismo e na resposta imunológica que causam elevações da temperatura das regiões afetadas. Com isso, uma câmera especializada (Figura 2) capta essas diferenças de temperatura por meio de excitações do espectro eletromagnético (Figura 3).

Figura 2 – Exemplo de câmera termográfica



(MUNDOGEO, 2020)

Figura 3 – Funcionamento de um espectro eletromagnético



(FERNANDES, 2015)

2.2 Redes Neurais Convolucionais (CNN)

Variante do perceptron de multicamadas, a rede neural convolucional (CNN) é uma arquitetura baseada em um processo biológico de processamento de dados. Esse tipo de rede tem maior utilização em aplicações de detecção, classificação e reconhecimento em imagens e vídeos. CNNs são dividida em estágios, em que geralmente os primeiros são constituídos por camadas de convolução e de pooling, seguidas de camadas completamente conectadas ou de softmax.

As CNNs, baseadas nas redes neurais do tipo feedforward, tem um grande potencial para analisar e classificar imagens. Duas características são necessárias serem destacadas sobre os classificadores da CNN: a convolução e o pooling.

A convolução possibilita que sejam atribuídas diferentes funções e pesos descobertos pelo algoritmo durante o processo de treinamento da rede neural, para gerar o feature-map em cada camada oculta. Já a camada de pooling é utilizada para reduzir e simplificar um dado, de modo que isso torna a generalização da informação mais eficaz.

Early stopping (ou parada precoce) é uma técnica utilizada para prevenir o overfitting (ajustes excessivos) de uma rede por meio da limitação da quantidade de épocas. Já épocas, em redes profundas, diz respeito ao o número de vezes que um algoritmo de

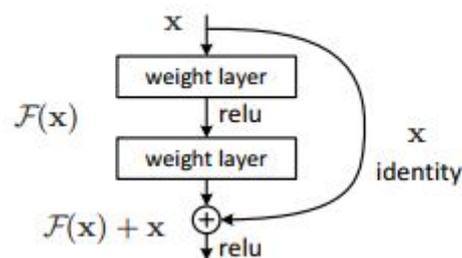
aprendizado vê o conjunto de dados completo. Por fim, transferência de aprendizagem (ou transfer learning) tem como ideia a utilização de conhecimento aprendido em uma base de dados maior aplicado em outras bases de dados, ou seja, o processo de aprendizado não começa do zero.

Tendo isto em mente, neste trabalho, as CNNs foram desenvolvidas para aceitar como entrada imagens da região de interesse do banco de dados DMR-IR (SILVA et al., 2014), e retornarem a classe das imagens de entrada: câncer ou saudável (não-câncer). A seguir apresentamos as duas redes usadas neste trabalho bem como as métricas que foram utilizadas para as comparações.

2.2.1 Resnet 50

Depois de uma quantidade de camadas, a acurácia de uma rede neural tende a piorar, e uma maneira utilizada para prevenir esta degradação é o grande diferencial da Resnet com as demais redes. O aprendizado residual, utiliza dos valores de entrada para influenciar a saída final de cada bloco conforme mostra a Figura 4. (HE et al., 2016)

Figura 4 – Modelo de funcionamento de uma Resnet50

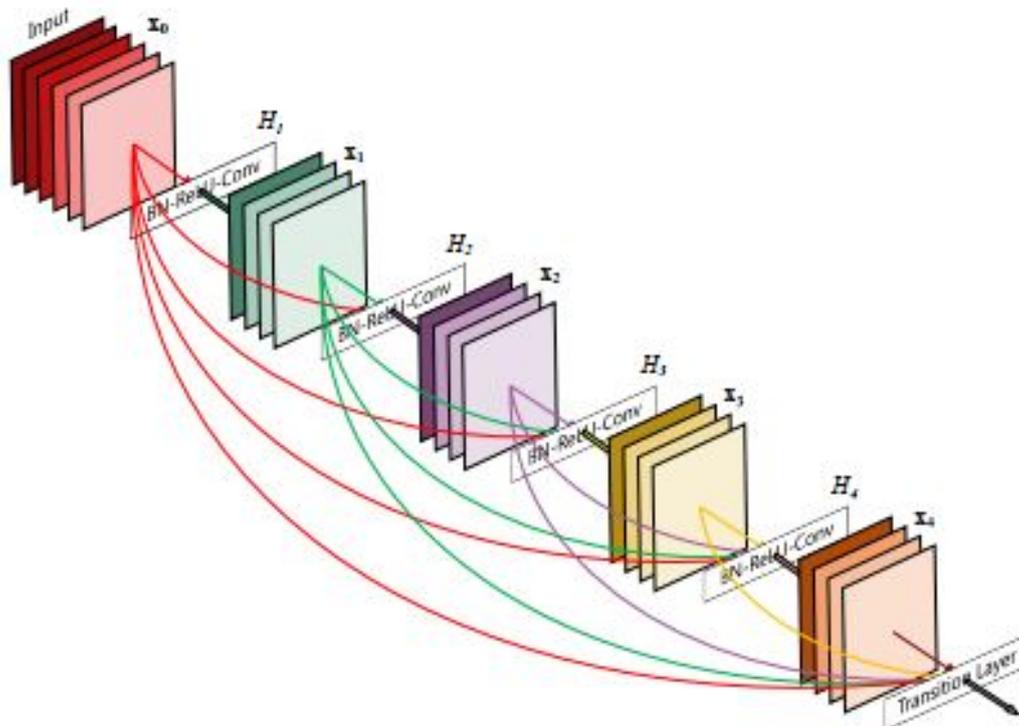


(HE et al., 2016)

2.2.2 Densenet 201

Uma outra maneira de prevenir a degradação da rede neural após uma grande quantidade de camadas é a proposta pela Densenet, em que cada camada recebe todos os feature-maps anteriores como entrada, tornando ela uma rede muito otimizada, porém uma rede muito pesada e difícil de ser processada. A Figura 5 apresenta um exemplo da Densenet. (HUANG et al., 2017)

Figura 5 – Modelo de funcionamento de uma Densenet210



(HUANG et al., 2017)

2.2.3 Métricas de avaliação

Para avaliação dos classificadores podem ser utilizadas diversas métricas, sendo que as mais comuns e as utilizadas nesse estudo são a sensibilidade, a especificidade, a acurácia e o F1-Score. Mas para compreendê-las é necessário entender conceitos da área da saúde de resultado:

- verdadeiro positivo (TP): número de amostras rotuladas como doentes e que são identificadas como doentes.
- verdadeiro negativo (TN): número de amostras rotuladas como saudáveis e que são identificadas como saudáveis.
- falso positivo (FP): número de amostras rotuladas como saudáveis e que são identificadas como doentes.
- falso negativo (FN): número de amostras rotuladas como doentes e que são identificadas como saudáveis.

(BARATLOO et al., 2015)

A partir desses conceitos, são calculadas as métricas citadas anteriormente, sendo:

- Sensibilidade: habilidade de determinar as imagens rotuladas como doentes de forma correta.

Figura 6 – Fórmula de sensibilidade

$$\text{Sensibilidade} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

- Especificidade: habilidade de determinar as imagens rotuladas como saudáveis de forma correta.

Figura 7 – Fórmula de especificidade

$$\text{Especificidade} = \frac{\text{TN}}{\text{TN} + \text{FP}}$$

- Acurácia: habilidade do modelo diferenciar a imagem nas classes saudáveis e doente corretamente, sendo a proporção de verdadeiros positivos e verdadeiros negativos sobre todos os casos avaliados.

Figura 8 – Fórmula de acurácia

$$\text{Acurácia} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

- Precisão: habilidade de determinar os verdadeiros positivos dentre todas as imagens rotuladas como positivas.

Figura 9 – Fórmula de precisão

$$\text{Precisão} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

- F1-score: média harmônica entre precisão e sensibilidade.

Figura 10 – Fórmula de f1-score

$$\text{F1-Score} = \frac{2 * \text{Precisão} * \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}}$$

Essas métricas podem ser representadas visualmente pela matriz de confusão, ou matriz de erro, como mostrado na Figura 11, em que cada linha representa as instâncias da classe prevista e as colunas representam a classe em si (ou vice-versa) para uma matriz de tamanho NxN (VISA et al., 2011).

Na Figura 11, temos o exemplo de que das 18 classificações como sendo patológicas, em 77.8% das vezes a predição estava correta (14 vezes) e em 22.2% estavam erradas (4). Para as 22 amostras classificadas como sendo normais, em 72.7% ele acerta (16) e 27.3% ele erra (6). Também existe a informação da acurácia localizada na última linha e na última coluna: 75%. A sensibilidade e a especificidade podem ser visualizadas na última linha da matriz de confusão, com os valores de 70% e 80%, respectivamente. Podemos também extrair os valores dos VP, FP, FN, VN da matriz, são eles: 14, 4, 6 e 16, respectivamente. (CHAVES et al., 2020)

Figura 11 – Exemplo de matriz de confusão

		Matriz de confusão		
Doentes	Verdadeiro Positivo	14 35.0%	Falso Negativo 4 10.0%	Sensibilidade 77.8% 22.2%
	Falso Positivo	6 15.0%	Verdadeiro Negativo 16 40.0%	Especificidade 72.7% 27.3%
Saudáveis	Precisão	70.0% 30.0%	Valor Preditivo Negativo 80.0% 20.0%	Acurácia 75.0% 25.0%
		Doentes	Saudáveis	

(CHAVES et al., 2020)

3 Revisao Bibliográfica

3.1 Trabalhos correlatos

Já existem alguns trabalhos na mesma linha de pesquisa para detecção do câncer de mama por meio de imagens termográficas:

Em (EKICI; JAWZAL, 2020), foi proposto um algoritmo para extração de traços característicos da mama baseado em bio-dados, análise das imagens e estatística das imagens. Esses traços foram extraídos das imagens térmicas capturadas por uma câmera térmica e foram usados para classificar as imagens da mama como normais ou suspeitas utilizando das redes neurais convolucionais (CNNs) otimizadas pelo algoritmo de Bayes. Esse algoritmo proposto obteve uma taxa de precisão de 98,95% para o conjunto de imagens térmicas de 140 indivíduos.

Um estudo feito por (ZULUAGA-GOMEZ et al., 2020) foi extremamente interessante porque tinha como objetivo demonstrar que os sistemas de diagnóstico auxiliados por computador (CAD) baseados em CNNs são mais rápidos, confiáveis e robustos do que outras técnicas. E, para isso, realizaram um estudo da influência do pré-processamento de dados, aumento de dados e tamanho do banco de dados versus um conjunto proposto de modelos CNNs.

Os modelos das CNNs deste estudo obtiveram uma maior precisão (92%) e pontuação F1-score (92 %) que supera várias arquiteturas de última geração, como ResNet50, SeResNet50 e Inception. Além disso, demonstraram que um modelo CNN que implementa técnicas de aumento de dados atinge métricas de desempenho idênticas em comparação com um CNN que usa um banco de dados até 50 % maior. (ZULUAGA-GOMEZ et al., 2020).

Outro estudo interessante foi feito por um grupo de pesquisadores da Indonésia (ROSLIDAR et al., 2019). Eles utilizaram o conjunto de dados de imagens banco de dados DMR-IR (SILVA et al., 2014) para treinar modelos de CNNs (ResNet101, DenseNet, MobileNetV2, and ShuffleNetV2). Durante o treinamento foi definida a taxa de aprendizado em 0.001 e utilizadas três épocas diferentes para as iterações de treinamento, 10, 20 e 30.

Os resultados do treinamento mostraram que o ResNet101 e o DenseNet com redes profundas têm 100% de precisão apenas em 10 épocas, enquanto que MobileNetV2 e ShuffleNetV2 precisam, respectivamente, de 20 épocas e 30 épocas de treinamento para atingir 100% de precisão. Durante a avaliação do desempenho de cada modelo pré-treinado, a DenseNet conseguiu classificar todo o conjunto de dados de teste corretamente (ROSLIDAR et al., 2019).

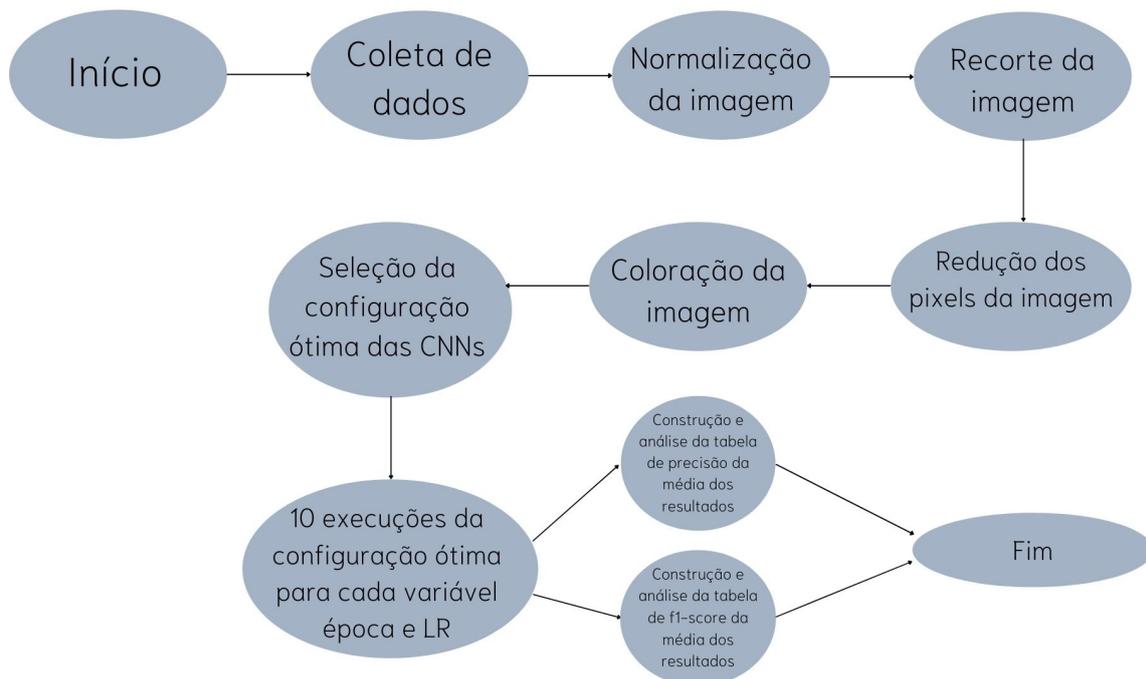
Em 2021, pesquisadores brasileiros (Gonçalves, Souza e Fernandes (2021)) avaliaram a performance de 3 CNNs (VGG16, Resnet 50 e Densenet 201) frente métricas de acurácia, sensibilidade, especificidade e F1-score para detecção do cancer de mama. Os melhores resultados encontrados foram de 92% para F1-score, 91.67% para acurácia, 100% para sensibilidade e 83.3% para especificidade obtidos com a Densenet. Foram usadas 38 imagens estáticas e o banco era balanceado (38 saudáveis e 38 doentes).

Um outro estudo desenvolvido por (CHATTERJEE et al., 2021) propôs um modelo de dois estágios para detecção de câncer de mama que também utiliza imagens termográficas, sendo que inicialmente, as informações foram extraídas das imagens usando a rede neural convolucional VGG16. Logo após, foi utilizado o algoritmo meta-heurístico chamado Dragonfly Algorithm que usa o método Grunwald-Letnikov para selecionar o subconjunto ótimo destas features. A estrutura de dois estágios proposta foi avaliada também no banco de dados DMR-IR (SILVA et al., 2014). O modelo proposto filtrou com eficiência recursos não essenciais e teve 100% de precisão de diagnóstico no conjunto de dados padrão, com 82% menos recursos em comparação com o modelo VGG16.

4 Metodologia

Neste capítulo são descritas a base de dados utilizada, detalhes do pré-processamento e do processamento para analisar as taxas de F1-Score e de precisão das CNNs escolhidas. A Figura 12 apresenta o fluxograma de metodologia do estudo.

Figura 12 – Fluxograma do estudo



4.1 Banco de Dados

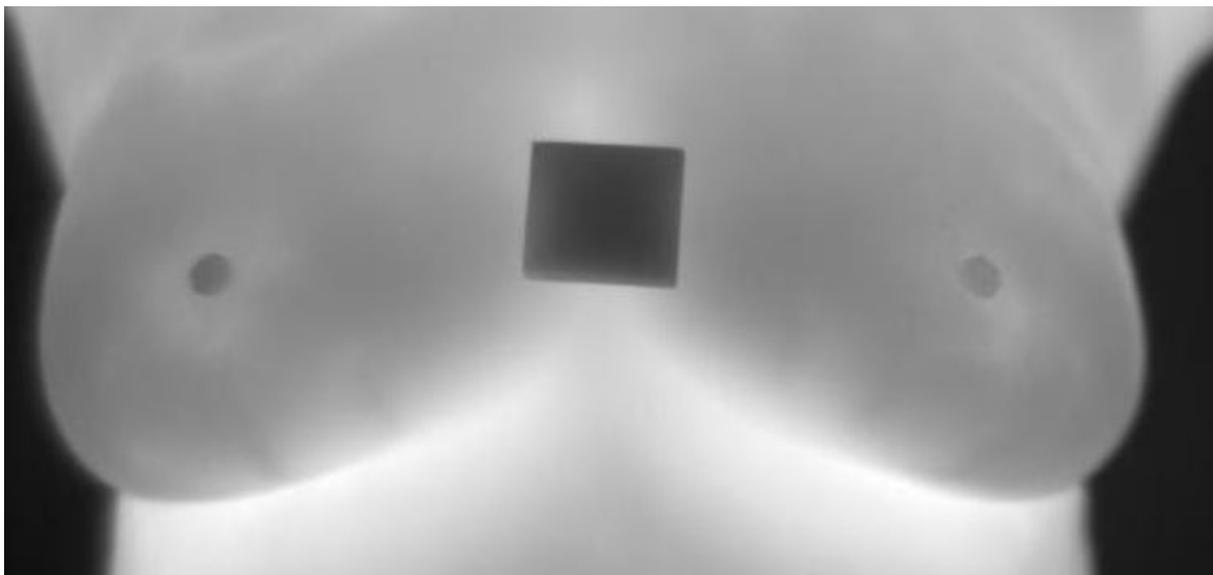
Durante este projeto de graduação, foi utilizado o banco de dados DMR-IR inicialmente proposto em (SILVA et al., 2014) e disponível gratuitamente em <http://visual.ic.uff.br/dmi/> fornecido pela Universidade Federal Fluminense (UFF), que contém imagens térmicas estáticas e dinâmicas de pelo menos 46 com mulheres com a neoplasia mamária e 192 sem a patologia, que foram obtidas através da câmera FLIR SC-620 com resolução de 640 x 480 pixels, onde cada pixel representa um valor de temperatura. Uma imagem estática é uma única imagem do paciente (em um determinado tempo t). Já as imagens dinâmicas são compostas por um conjunto de 22 imagens do paciente em tempos diferentes porém capturadas em sequência.

Cada paciente analisada possui 27 imagens, sendo 22 dinâmicas tiradas ao longo de 5 minutos, as quais não foram utilizadas nesse trabalho, e 5 estáticas de diferentes ângulos que possuem a região de interesse, nas poses: frontal (Imagens (a) das Figuras 13 e 14),

lateral esquerda de 45° (Imagens (b) das Figuras 13 e 14) e 90° (Imagens (d) das Figuras 13 e 14) e lateral direita de 45° (Imagens (c) das Figuras 13 e 14) e 90° (Imagens (e) das Figuras 13 e 14). No presente estudo foram analisadas somente as imagens estáticas frontais e um detalhe importante sobre esta base de dados é que ela não indica a posição do tumor, somente classifica o paciente como "com câncer" ou "sem câncer".

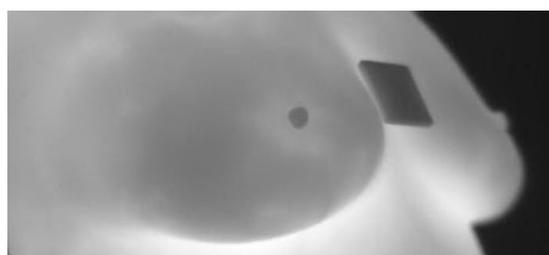
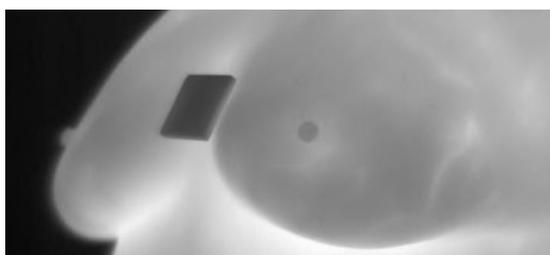
Na época da coleta dos dados, havia apenas 38 pacientes doentes no banco de dados, portanto, para balancear-lo, foram analisadas apenas 38 pacientes saudáveis, os quais escolhidos aleatoriamente.

(a) Frontal



(b) Lateral esquerda de 45°

(c) Lateral direita de 45°



(d) Lateral esquerda de 90°

(e) Lateral direita de 90°

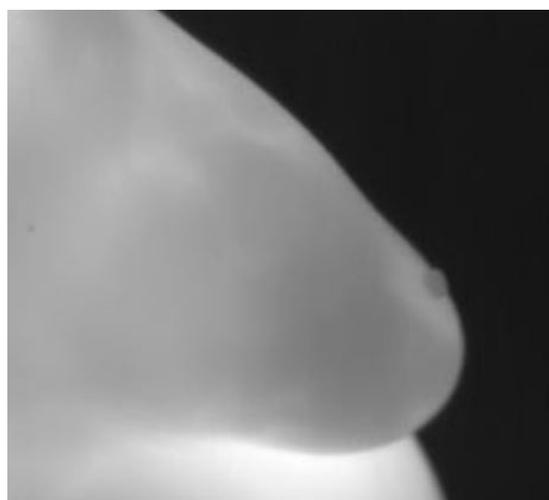
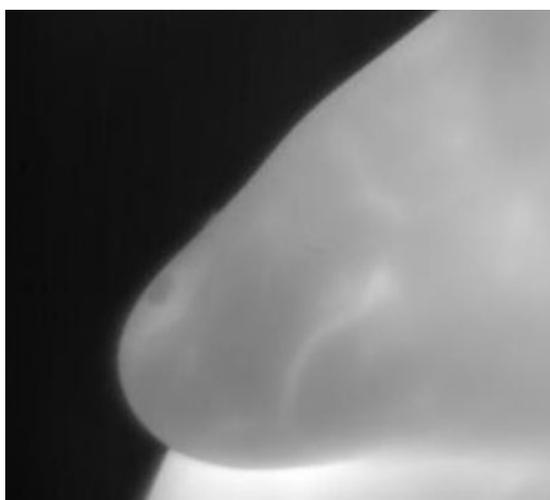


Figura 13 – Paciente Saudável

(a) Frontal



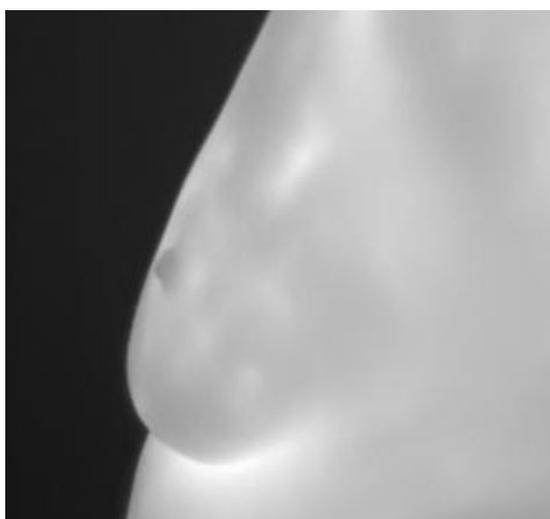
(b) Lateral Esquerda de 45°



(c) Lateral Direita de 45°



(d) Lateral Esquerda de 90°



(e) Lateral Direita de 90°

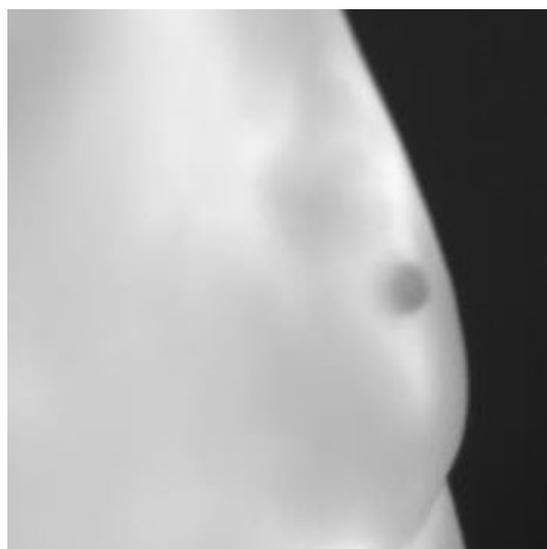


Figura 14 – Paciente com neoplasia mamária

4.2 Pré-processamento

O pré-processamento das imagens térmicas originais ocorreu em 4 etapas. Tal processamento foi necessário para que as imagens pudessem ser passadas como entrada das CNNs.

Figura 15 – Imagem térmica original.



4.2.1 1ª Etapa - Normalização

As imagens foram normalizadas através da fórmula:

$$255 * (P_{ij} - L) / (H - L) \quad (4.1)$$

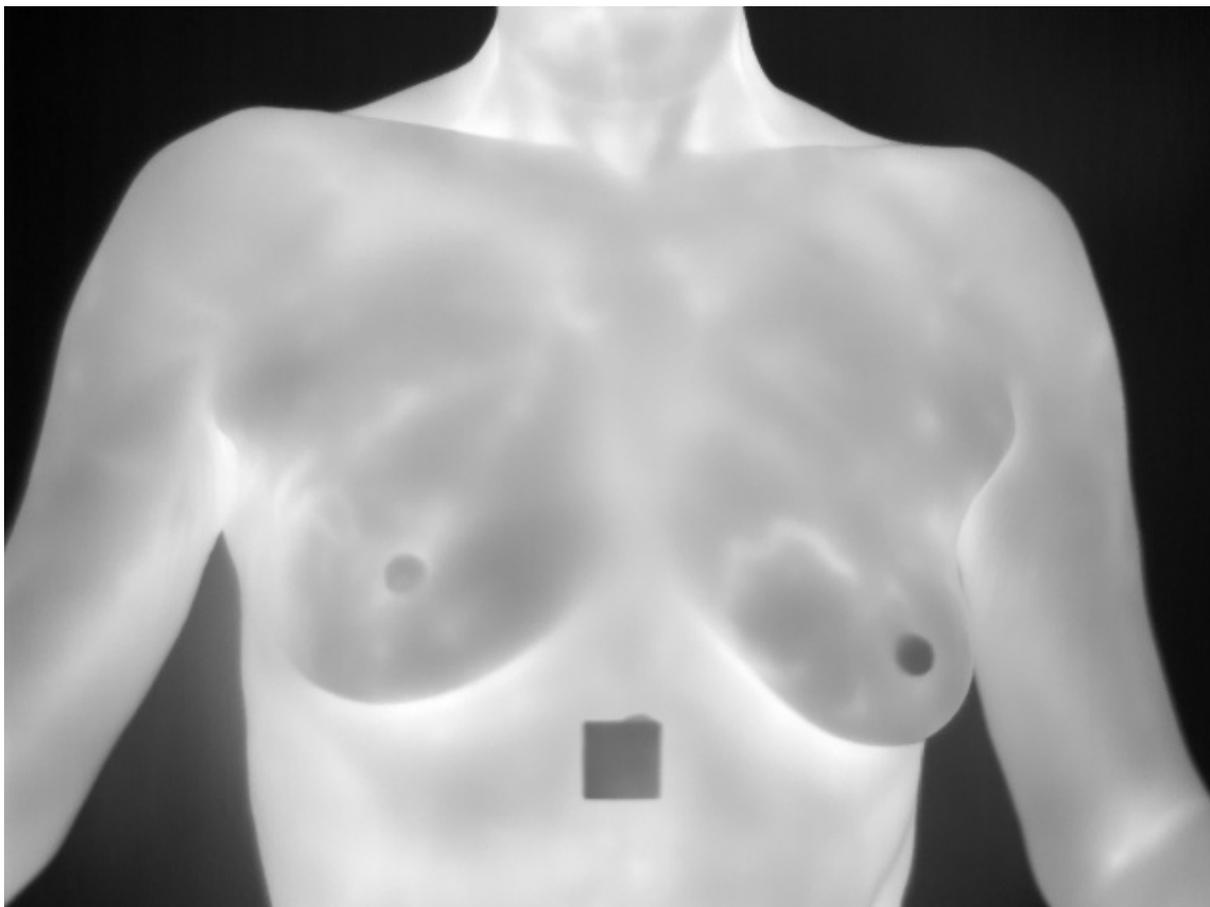
Onde:

P_{ij} = valor do pixel da imagem a ser normalizada na matriz de linha i e coluna j .

H = maior valor entre todos os pixels da imagem a ser normalizada

L = menor valor entre todos os pixels da imagem a ser normalizada

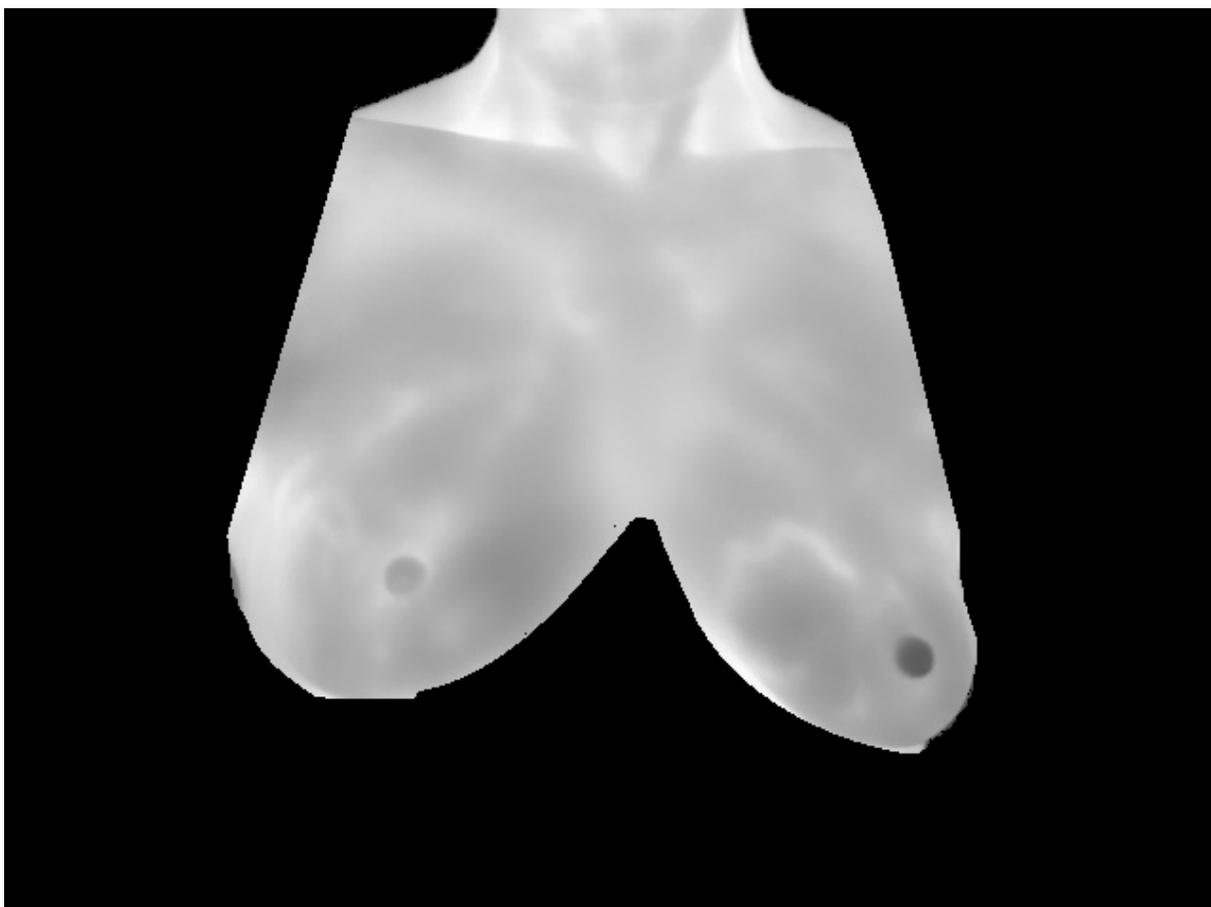
Figura 16 – Imagem térmica normalizada.



4.2.2 2ª Etapa - Recorte

As imagens normalizadas foram recortadas manualmente para a seleção da região de interesse (ROI). A forma e tamanho da ROI foram definidas com base em (BAFFA; COELHO; CONCI, 2021).

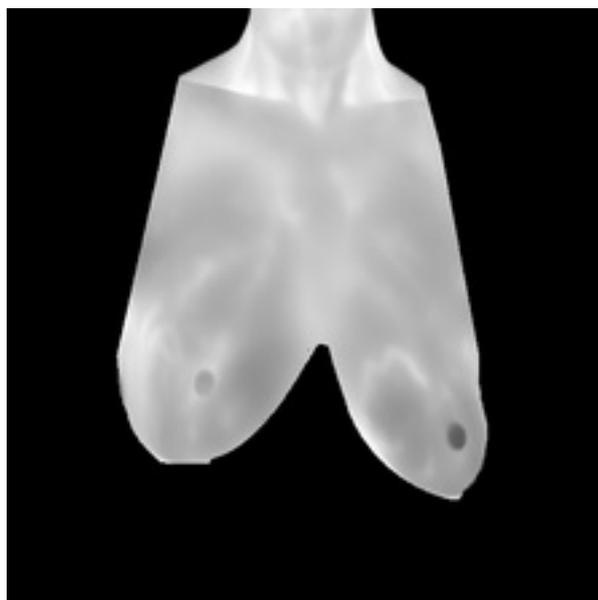
Figura 17 – Imagem da região de interesse normalizada.



4.2.3 3ª Etapa - Redução dos Pixels

As imagens foram reduzidas para 224 por 224 pixels pois as redes utilizadas foram treinadas com imagens deste tamanho.

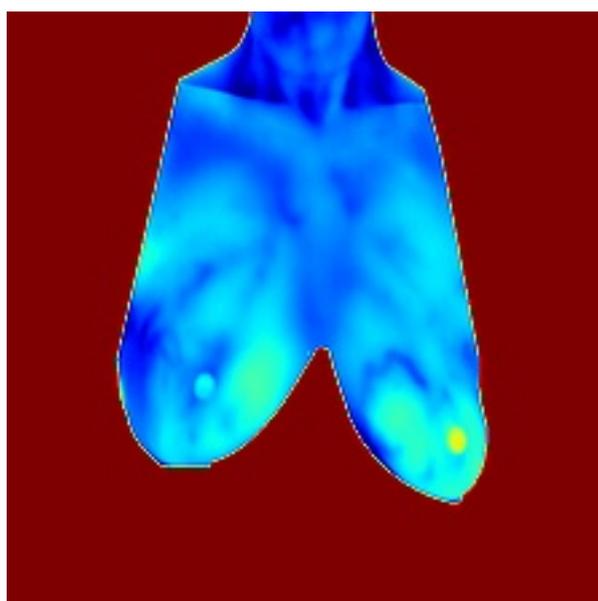
Figura 18 – Imagem da região de interesse normalizada e reduzida.



4.2.4 4ª Etapa - Coloração

Por fim, as redes usadas neste trabalho foram treinadas com imagens coloridas. Ou seja, a rede espera como entrada 1 matriz com 3 dimensões (uma imagem colorida). Sendo assim, as imagens da região de interesse normalizadas e reduzidas foram coloridas utilizando o colormap jet conforme sugerido por (CABIOĞLU; OĞUL, 2020)

Figura 19 – Imagem colorida.



4.3 Classificação

Nesta etapa do trabalho, as imagens que foram processadas nos passos anteriores são usadas para o treinamento e posterior teste das redes em análise, de modo que 70% (n=26) das imagens do banco de dados são para treinamento, 15% (n=6) para testes e 15% (n=6) para validação.

As redes Resnet 50 e a Densenet 201 já estavam pré-treinadas portanto foi aplicado transferência de aprendizagem (transfer learning). Os autores (GONÇALVES; SOUZA; FERNANDES, 2021) forneceram as implementações das redes para aplicação neste trabalho. As redes possuem as possíveis configurações:

- a) 1 camada completamente conectada (padrão da resnet e densenet);
- b) 2 camadas completamente conectadas com (256 neurônios de entrada e saída da primeira camada, 256 de entrada e 2 neurônios de saída da segunda);
- c) 2 camadas completamente conectadas com (512 neurônios de entrada e saída da primeira camada, 512 de entrada e 2 neurônios de saída da segunda);
- d) 2 camadas completamente conectadas com (1024 neurônios de entrada e saída da primeira camada, 1024 de entrada e 2 neurônios de saída da segunda);
- e) 3 camadas completamente conectadas de (4096 neurônios de entrada e saída da primeira camada, 1024 de entrada e 2 neurônios de saída da segunda)
- f) 3 camadas completamente conectadas com (4096 neurônios de entrada e saída da primeira camada, 4096 de entrada e 2 neurônios de saída da segunda).

No processamento, após a execução inicial de todas as configurações, foi escolhida a configuração da letra 'd' citada acima, devido à sua performance superior quando comparada com as outras. Após esta escolha, para tornar a análise dos resultados mais fidedigna à realidade, foi rodada 10 vezes para cada CNN:

- 10 épocas e taxas de aprendizagem de 0.1, 0.01, 0.001, 0.0001
- 30 épocas e taxas de aprendizagem de 0.1, 0.01, 0.001, 0.0001

5 Resultados e Discussões

Neste capítulo serão apresentados os resultados das análises e as discussões referentes à média das 10 execuções da configuração da letra 'd', citada anteriormente. Foi gerada uma tabela de precisão e uma de F1-Score com tais resultados.

Tabela 1 – Tabela de precisão da média de 10 execuções das CNNs com a configuração 2 FC com (1024,2)

	LR= 0.1		LR= 0.01		LR = 0.001		LR = 0.0001	
	épocas = 10	épocas = 30						
resnet	0,3212122	0,41	0,3012122	0,7268074	0,4821212	0,8067461	0,6029763	0,7934524
densenet	0,38	0,3931169	0,2545455	0,8583333	0,5433333	0,8964285	0,3539683	0,7166667

Tabela 2 – Tabela de F1-Score da média de 10 execuções das CNNs com a configuração 2 FC com (1024,2)

	LR= 0.1		LR= 0.01		LR = 0.001		LR = 0.0001	
	épocas = 10	épocas = 30						
resnet	0,2769374	0,4369049	0,3008914	0,7478577	0,4470992	0,6633701	0,4337607	0,7621978
densenet	0,3893941	0,3908263	0,2955883	0,6923378	0,5138096	0,724975	0,4377878	0,4530158

Através da tabela de precisão (Tabela 1), foi possível perceber que tanto com a Resnet 50, quanto com a Densenet 201, os bons resultados foram obtidos com 30 épocas, salvo para quando a learning rate estava com valor 0.1. Isso se deve ao fato de que 0.1 é uma taxa de aprendizagem muito alta, e quando alta, ela muda o comportamento da rede muito rapidamente, dificultando que esta obtenha resultados ótimos.

Com a taxa de aprendizagem no valor de 0.001, chegou-se nos melhores resultados: na Resnet50 se obteve aproximadamente 80,67% de precisão, enquanto na Densenet 201 aproximadamente 89,64% de precisão. No entanto, os resultados do presente estudo se mostraram inferiores a estudos anteriores, com os mesmos algoritmos, porém com desenhos de estudo diferentes: em (ZULUAGA-GOMEZ et al., 2020), obtiveram uma taxa de precisão de 92% com os algoritmos testados; em (EKICI; JAWZAL, 2020) a taxa de precisão obtida foi de 98,95 %; e em (ROSLIDAR et al., 2019) obtiveram uma taxa de 100% de precisão com os modelos testados.

O early stopping (parada precoce) na inteligência artificial, que é uma técnica famosa para solucionar problemas de overfitting, ao invés de melhorar, pioraram os resultados, visto que as piores performances para as duas CNNs foram quando a quantidade de épocas dos algoritmos foi 10. Atingiu os piores resultados quando a learning rate possuiu valor de 0.01, com a Resnet tendo a média de precisão de 10 execuções como aproximadamente 30,12% e a Densenet a média aproximadamente 25,45%.

Já na tabela do F1-Score (Tabela 2), Resnet50 teve uma performance melhor com a learning rate 0.0001 e 30 épocas (76,21% aproximadamente) do que com a learning rate 0.001 e 30 épocas (66,33% aproximadamente) que foi quando se teve a melhor precisão. Já Densenet201 continuou sendo superior com 30 épocas e learning rate 0.001 (72,49% aproximadamente). Ambas CNNs tiveram resultados melhores que em (GONÇALVES; SOUZA; FERNANDES, 2021), com a mesma configuração (2FC com (1024,2)), cujos dois algoritmos obtiveram F1-score menor que 70%.

Porém, também em (GONÇALVES; SOUZA; FERNANDES, 2021), os resultados finais foram superiores aos melhores deste estudo, tanto na Resnet (que teve como melhor resultado de F1-Score aproximadamente 83,33%) quanto na Densenet (no melhor caso obteve F1-Score de aproximadamente 92,30%).

Na (Figura 20), pode-se verificar as métricas de avaliação do melhor resultado, obtido com a rede Densenet 201 com 30 épocas e learning rate de 0.001.

Figura 20 – Matriz de confusão do melhor resultado Densenet 201 da base de validação

		Matriz de confusão				
Doentes	Verdadeiro Positivo	5	Falso Negativo	1	Sensibilidade	83,333 %
	Falso Positivo	0	Verdadeiro Negativo	6	Especificidade	100%
Saudáveis	Precisão	100%	Valor Preditivo Negativo	85,714286%	Acurácia	91,666667%
		Doentes	Saudáveis			

O f1-score deste melhor resultado foi de, aproximadamente, 90,90%.

Com esses valores, pode-se concluir que o tamanho limitado da amostra interfere diretamente na avaliação de performance do algoritmo, visto que, apesar de apresentar 100% de precisão, bastou 1 resultado falso negativo para deteriorar o valor de f1-score.

Na (Figura 21), pode-se verificar as métricas de avaliação do melhor resultado,

obtido com a rede Resnet 50 com 30 épocas e learning rate de 0.001.

Figura 21 – Matriz de confusão do melhor resultado Resnet 50 da base de validação

Matriz de confusão			
Doentes	Verdadeiro Positivo 5	Falso Negativo 1	Sensibilidade 83,333 %
Saudáveis	Falso Positivo 1	Verdadeiro Negativo 5	Especificidade 83,333 %
	Precisão 83,333 %	Valor Preditivo Negativo 83,333 %	Acurácia 83,333 %
	Doentes	Saudáveis	

O f1-score deste melhor resultado foi de, aproximadamente, 83,33%.

Com esses valores, também pode-se concluir que o tamanho limitado da amostra interfere diretamente na avaliação de performance do algoritmo, visto que, as métricas de precisão e f1-score deterioraram com apenas 1 valor falso negativo e 1 valor falso positivo.

6 Conclusão

O uso de imagens termográficas para detecção de câncer de mama é uma técnica promissora para auxiliar no diagnóstico desta doença. Além de proporcionar diagnóstico precoce, é uma técnica indolor, livre de radiação, viabiliza a detecção da doença em mamas nas quais outras técnicas apresentam limitações e é de baixo custo.

Mesmo sendo uma técnica promissora, a aplicação das CNNs nas imagens apenas com a região de interesse não obteve resultados superiores (no presente estudo) ao das imagens inteiras em relação às métricas de avaliação. No entanto, são necessários mais estudos com bancos de dados maiores para confirmar ou até mesmo refutar os achados do presente estudo, uma vez que imagens apenas da região de interesse excluiriam muitos detalhes desnecessários para a inteligência artificial.

Referências

- BAFFA, M.; COELHO, A.; CONCI, A. *Segmentação de Imagens Infravermelhas Para Detecção do Câncer de Mama Utilizando U-NET CNN*. Porto Alegre, RS, Brasil, 2021. 119–128 p. Disponível em: <<https://sol.sbc.org.br/index.php/sbcas/article/view/16058>>. Citado na página 22.
- BARATLOO, A. et al. Part 1: Simple definition and calculation of accuracy, sensitivity and specificity. *Emergency (Tehran, Iran)*, Shahid Beheshti University of Medical Sciences, v. 3, n. 2, p. 48–49, 2015. ISSN 2345-4563. 26495380[pmid]. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/26495380>>. Citado na página 12.
- BEZERRA, L. A. *Uso de imagens termográficas em tumores mamários para validação de simulação computacional*. [S.l.], 2007. Disponível em: <<https://repositorio.ufpe.br/handle/123456789/5486>>. Acesso em: 29 abril. 2021. Citado na página 6.
- BORCHARTT, T. B. et al. Breast thermography from an image processing viewpoint: A survey. *Signal Processing*, v. 93, n. 10, p. 2785–2803, 2013. Citado na página 6.
- CABIOĞLU, Ç.; OĞUL, H. Computer-aided breast cancer diagnosis from thermal images using transfer learning. In: ROJAS, I. et al. (Ed.). *Bioinformatics and Biomedical Engineering*. Cham: Springer International Publishing, 2020. p. 716–726. ISBN 978-3-030-45385-5. Citado na página 24.
- CANCER, I. N. de. *Conceito e Magnitude do câncer de mama*. [S.l.], 2018. Disponível em: <<https://www.inca.gov.br/controlado-cancer-de-mama/conceito-e-magnitude>>. Acesso em: 28 abril. 2021. Citado na página 6.
- CHATTERJEE, S. et al. Breast cancer detection from thermal images using a grunwald-letnikov-aided dragonfly algorithm-based deep feature selection method. *Computers in Biology and Medicine*, p. 105027, 2021. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482521008210>>. Citado na página 16.
- CHAVES, E. et al. Evaluation of transfer learning of pre-trained cnns applied to breast cancer detection on infrared images. *Appl. Opt.*, OSA, v. 59, n. 17, p. E23–E28, Jun 2020. Disponível em: <<http://ao.osa.org/abstract.cfm?URI=ao-59-17-E23>>. Citado na página 14.
- EKICI, S.; JAWZAL, H. Breast cancer diagnosis using thermography and convolutional neural networks. *Medical Hypotheses*, Elsevier, v. 137, p. 109542, 2020. Citado 2 vezes nas páginas 15 e 26.
- FERNANDES, H. *Fiber orientation analysis of carbon fiber-reinforced polymers by infrared thermography*. [S.l.], 2015. Citado na página 10.
- GONÇALVES, C. B.; SOUZA, J. R.; FERNANDES, H. Classification of static infrared images using pre-trained cnn for breast cancer detection. In: *2021 IEEE 34th International Symposium on Computer-Based Medical Systems (CBMS)*. [S.l.: s.n.], 2021. p. 101–106. Citado 3 vezes nas páginas 16, 25 e 27.

- HE, K. et al. *Deep Residual Learning for Image Recognition*. [S.l.], 2016. 770-778 p. Citado na página 11.
- HUANG, G. et al. *Densely Connected Convolutional Networks*. [S.l.], 2017. 2261-2269 p. Citado 2 vezes nas páginas 11 e 12.
- JUNIOR, J. S. da S. *O que é infravermelho?* [S.l.], 2021. Disponível em: <<https://brasilecola.uol.com.br/o-que-e/fisica/o-que-e-infravermelho.htm>>. Acesso em: 22 novembro. 2021. Citado 2 vezes nas páginas 8 e 9.
- KANDLIKAR, S. G. et al. Infrared imaging technology for breast cancer detection – current status, protocols and new directions. *International Journal of Heat and Mass Transfer*, v. 108, p. 2303–2320, 2017. ISSN 0017-9310. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0017931016336031>>. Citado na página 7.
- KITOR, G. L. *Dispersão da Luz*. [S.l.], 2021. Disponível em: <<https://www.infoescola.com/optica/dispersao-da-luz/>>. Citado na página 8.
- LELES, A. C. Q. *Desenvolvimento de procedimento e análise de imagens térmicas para a identificação do câncer de mama*. [S.l.], 2015. Disponível em: <<https://repositorio.ufu.br/handle/123456789/15022>>. Acesso em: 29 mar. 2021. Citado na página 6.
- LESSA, V.; MARENGONI, M. Applying artificial neural network for the classification of breast cancer using infrared thermographic images. In: CHMIELEWSKI, L. J. et al. (Ed.). *Computer Vision and Graphics*. Cham: Springer International Publishing, 2016. p. 429–438. ISBN 978-3-319-46418-3. Citado na página 6.
- MILOEVIĆ, M.; JANKOVIC, D.; PEULIC, A. Thermography based breast cancer detection using texture features and minimum variance quantization. *EXCLI Journal*, v. 13, p. 1204 – 1215, 2014. Disponível em: <<https://www.excli.de/index.php/excli/article/view/773>>. Citado na página 6.
- MUNDOGEO. *Câmeras termográficas podem apoiar o combate à Covid-19*. [S.l.], 2020. Disponível em: <<https://mundogeo.com/2020/04/09/cameras-termograficas-podem-apoiar-o-combate-a-covid-19/>>. Citado na página 9.
- NG, E. Y. K. A review of thermography as promising non-invasive detection modality for breast tumor. *International Journal of Thermal Sciences*, v. 48, p. 849–859, 2009. Citado na página 9.
- ROSLIDAR, R. et al. *A Study of Fine-Tuning CNN Models Based on Thermal Imaging for Breast Cancer Classification*. [S.l.], 2019. 77-81 p. Citado 2 vezes nas páginas 15 e 26.
- SILVA, L. et al. A new database for breast research with infrared image. *Journal of Medical Imaging and Health Informatics*, v. 4, p. 92–100, 03 2014. Citado 4 vezes nas páginas 11, 15, 16 e 17.
- VISA, S. et al. *Confusion Matrix-based Feature Selection*. [S.l.], 2011. Citado na página 14.

ZULUAGA-GOMEZ, J. et al. A cnn-based methodology for breast cancer diagnosis using thermal images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, Taylor & Francis, p. 1–15, 2020. Citado 2 vezes nas páginas 15 e 26.