

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Tiago da Silva e Souza Pinto

**Segmentação automática de região de interesse  
em imagens termográficas da mama utilizando  
redes profundas**

**Uberlândia, Brasil**

**2023**

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Tiago da Silva e Souza Pinto

**Segmentação automática de região de interesse em  
imagens termográficas da mama utilizando redes  
profundas**

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: Henrique Coelho Fernandes

Universidade Federal de Uberlândia – UFU

Faculdade de Computação

Bacharelado em Ciência da Computação

Uberlândia, Brasil

2023

Tiago da Silva e Souza Pinto

## **Segmentação automática de região de interesse em imagens termográficas da mama utilizando redes profundas**

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, 16 de novembro de 2023:

---

**Henrique Coelho Fernandes**  
Orientador

---

**Marcelo Zanchetta do Nascimento**

---

**Mauricio Cunha Escarpinati**

Uberlândia, Brasil  
2023

# Agradecimentos

Primeiramente, quero agradecer a Deus por toda graça obtida.

Agradeço à minha família, em especial minha mãe Edivane, meu irmão Vinicius e minha madrinha Eliana, pelo apoio incondicional ao longo dessa jornada.

Agradeço a minha namorada Isabela por todo amor e compreensão, que me ajudou a superar todas as dificuldades e seguir em frente em busca dos meus objetivos.

Agradeço também aos meus amigos Pedro e Danilo, que me acolheram nessa minha aventura de vir estudar em uma cidade tão distante. E também, aos meus amigos da minha cidade natal, que mesmo distantes me ajudaram compartilhando momentos de alegria.

Ao meu orientador Henrique, quero expressar minha gratidão por sua orientação, paciência e sabedoria.

Por fim, agradeço a todos os que de alguma forma contribuíram para o sucesso deste trabalho, mesmo que não tenham sido mencionados nominalmente.

# Resumo

O câncer de mama é o tipo de câncer mais incidente em mulheres no Brasil, com previsão de mais de 73 mil novos casos previstos para o ano de 2023. A detecção precoce desse tipo de câncer aumenta significativamente as chances de sucesso no tratamento. Nesse contexto, a termografia infravermelha se destaca como uma técnica não invasiva, que pode ser aplicada até mesmo em mulheres mais jovens para detecção do câncer de mama. A análise de imagens termográficas da mama para detecção do câncer de mama é um tema abordado na literatura, e nesse sentido, a segmentação da região de interesse dessas imagens tem como objetivo remover algumas informações que podem ser consideradas como ruídos para a detecção automática da doença. Este trabalho propõe um método de segmentação de imagens termográficas da mama utilizando a Rede Neural Convolutacional DeepLabV3+, e obteve como resultado 98,69%, 97,18% e 98,48% de médias de acurácia, Interseção pela União e precisão atingindo respectivamente.

**Palavras-chave:** Segmentação de imagens, Câncer de Mama, Termografia infravermelha, Região de Interesse, Rede Neural Convolutacional

# Lista de ilustrações

Figura 1 – Imagem termográfica da mama - disponível em <i>Database For Mastology Research</i> . . . . .	12
Figura 2 – Exemplo de segmentação de imagem - adaptado de (KIRILLOV et al., 2019) . . . . .	14
Figura 3 – Estágios de uma camada de uma CNN - adaptado de Goodfellow, Bengio e Courville (2016) . . . . .	16
Figura 4 – Modelo DeepLabV3+ proposto por Chen et al. (2018) - adaptado de Chen et al. (2018) . . . . .	16
Figura 5 – Resultado da conjunção de arestas após as três etapas - extraído de Marques (2012) . . . . .	19
Figura 6 – Fluxograma do método proposto por Baffa, Cheloni e Lattari (2016) . . . . .	19
Figura 7 – Arquitetura U-Net utilizada por Jakhar, Kaur e Gupta (2019) - adaptado de Jakhar, Kaur e Gupta (2019) . . . . .	20
Figura 8 – Diagrama das etapas da abordagem . . . . .	22
Figura 9 – Posições para captura das imagens - extraído de Motta (2010) . . . . .	23
Figura 10 – Exemplo extraído da base de dados . . . . .	24
Figura 11 – Exemplo de aplicação da rotação . . . . .	26
Figura 12 – Resultados obtidos na melhor execução do experimento . . . . .	29
Figura 13 – Imperfeições percebidas na melhor execução do experimento . . . . .	30

# Lista de tabelas

Tabela 1 – Resultados dos dados de teste de cada execução com 30 épocas . . . .	28
---	----

# Lista de abreviaturas e siglas

CNN	Rede Neural Convolutacional, do inglês <i>convolutional neural network</i>
IoU	Interseção pela União, do inglês <i>intersection over union</i>
ML	Aprendizado de máquina, do inglês <i>machine learning</i>
ROI	Região de Interesse, do inglês <i>region of interest</i>



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>9</b>
1.1	Justificativa	10
1.2	Objetivos	10
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>11</b>
2.1	Câncer de Mama	11
2.2	Termografia infravermelha	11
2.3	Aprendizado de máquina	12
2.4	Segmentação de imagem	13
2.4.1	Uso de aprendizado profundo para segmentação de imagem	14
2.5	Redes Neurais Convolucionais	15
2.5.1	DeepLabV3+	15
2.5.2	Transferência de aprendizado	17
<b>3</b>	<b>TRABALHOS CORRELATOS</b>	<b>18</b>
<b>4</b>	<b>DESENVOLVIMENTO</b>	<b>22</b>
4.1	Base de Dados	22
4.2	Métricas de avaliação	24
4.3	Aumento de dados	25
4.4	Segmentação	26
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>28</b>
<b>6</b>	<b>CONCLUSÃO</b>	<b>31</b>
	<b>REFERÊNCIAS</b>	<b>32</b>

# 1 Introdução

Segundo o Instituto Nacional de Câncer, no Brasil, dentre todas as neoplasias que atingem as mulheres, exceto pele não melanoma, a neoplasia mamária é a mais incidente, com estimativa de 73,61 mil novos casos para o ano de 2023, correspondente a uma taxa de 30,1%. Em 2021, 18,139 mil mulheres foram vítimas de câncer com localização primária na mama, referente a 16,4% das mortes por neoplasias (INCA, 2022).

O câncer de mama, na maioria dos casos, apresenta bom prognóstico quando tratado adequadamente e em tempo oportuno (INCA, 2022). As principais técnicas para a detecção do câncer de mama, como a mamografia, ultrassonografia e ressonância magnética, possuem algumas limitações, como uso de radiação nociva ao ser humano, o custo e a densidade do tecido na juventude. Por isso, pesquisadores são encorajados a pesquisarem técnicas alternativas, como a termografia (ZULUAGA-GOMEZ et al., 2021).

A termografia, diferente dos exames tradicionais, é uma técnica não invasiva, indolor e de baixo custo. Células anormais, como tumores, possuem uma alta atividade metabólica, uma das causas para a assimetria na distribuição da temperatura corporal. Por isso, imagens termográficas infravermelhas podem capturar a temperatura da mama e colaborar na detecção de anomalias (BAFFA; LATTARI, 2018). Considerando somente a mamografia, somente um em cada cinco municípios do Brasil tem equipamentos de mamografia (THOMAZ, 2020), o que mostra a necessidade da disseminação de técnicas mais acessíveis para a detecção de câncer de mama no sistema de Saúde Brasileiro.

A visão computacional busca replicar e automatizar a percepção visual humana por meio do uso de modelos matemáticos, algoritmos e abordagens baseadas em dados. Atualmente, ela está sendo usada em diversas aplicações, por exemplo, em imagens médicas, auxiliando especialistas, que antes precisavam fazer um rastreamento manual mais trabalhoso em tarefas que necessitam da análise dessas imagens. Em visão computacional, a segmentação de imagens, que busca agrupar *pixels* que possuem certa semelhança, sendo um dos problemas mais amplamente estudados (SZELISKI, 2021).

O uso da termografia infravermelha para a detecção do câncer de mama é um tema abordado por diversos pesquisadores. Diferentes estratégias têm sido abordadas, como *Support Vector Machine* (SVM) em Acharya et al. (2012) e Redes Neurais Convolucionais em Pramanik, Pramanik e Sarkar (2023) e Gonçalves, Souza e Fernandes (2021).

Segmentar a Região de Interesse (do inglês, Region of Interest - ROI) das imagens da mama, tem como objetivo separar o que deve ser analisado pelo classificador para extração de características, incluindo todos os tecidos da mama e os grupos de gânglios próximos, daquilo que não é relevante para classificação em tecido doente e tecido saudável

como pescoço e abdômen (BORCHARTT et al., 2013). Essa não é uma tarefa simples, devido à falta de limites claros e a natureza amorfa das imagens (ZHOU; LI; AGGARWAL, 2004).

## 1.1 Justificativa

Quando descoberto precocemente, o câncer de mama possui maior chance de ser tratado com sucesso, e exames de triagem feitos regularmente é a maneira mais confiável de se obter o diagnóstico precoce (SOCIETY, 2022). A termografia, uma técnica que pode ser aplicada para detecção do câncer de mama até mesmo em mulheres mais jovens, que possuem o tecido da mama mais denso, pode auxiliar na obtenção desse diagnóstico (BORCHARTT et al., 2013).

Partes das imagens termográficas que não fazem parte da mama podem ser consideradas ruídos para o classificador que irá fazer a detecção (MOTTA, 2010), portanto, a remoção automática dessas partes se torna relevante uma vez que ao se usar somente a região de interesse o classificador pode eventualmente alcançar melhores resultados no momento da classificação.

## 1.2 Objetivos

Este trabalho tem como objetivo geral a segmentação automática da região de interesse em imagens termográficas da mama utilizando redes profundas, removendo informações não referentes às mamas (plano de fundo, tórax, pescoço e braços) para que essas imagens segmentadas sejam utilizadas futuramente em outros trabalhos com objetivo de classificação para detecção do câncer de mama. Os objetivos específicos do trabalho são:

- utilizar uma rede pré-treinada para realizar a segmentação das imagens termográficas da mama,
- avaliar os resultados obtidos a partir de métricas como acurácia, IoU (Interseção pela União) e precisão,
- disponibilizar gratuitamente a metodologia de segmentação automática para ser usada em outros projetos que envolvam o tema câncer de mama e imagens termográficas.

## 2 Referencial teórico

Este capítulo possui como objetivo apresentar conceitos fundamentais que são utilizados no trabalho.

### 2.1 Câncer de Mama

O câncer, de maneira geral, ocorre quando as células se multiplicam de uma maneira desordenada, podendo se espalhar para outras áreas do corpo, além de não se submeterem a morte celular programada (BERNARDES et al., 2019). O câncer de mama geralmente pode aparecer em duas regiões, nos tubos que carregam o leite, chamados de ductos, ou nos lóbulos, glândulas que produzem o leite, com possibilidade de ocorrer em homens e mulheres, porém, é uma doença rara em homens (BORCHARTT et al., 2013).

Os fatores de risco permitem identificar mulheres com maior predisposição ao câncer de mama, dentre eles estão: a idade, em que a incidência aumenta conforme os anos até os 45-50 anos, o estilo de vida, pois o sobrepeso e o sedentarismo aumentam os riscos, fatores hereditários, visto que a presença da doença em familiares aumentam a probabilidade de desenvolver o câncer, entre outros (MARTÍN; HERRERO; ECHAVARRÍA, 2015).

Os exames mais comuns utilizados para o diagnóstico do câncer de mama, são a mamografia e o exame clínico, sendo o primeiro o padrão ouro para a doença e o principal método por imagem. Outros exames também podem auxiliar no diagnóstico, como a ultrassonografia, ressonância magnética, biópsia, entre outros (BERNARDES et al., 2019). Porém, a mamografia apresenta menor sensibilidade em mulheres mais jovens que geralmente possuem mamas mais densas (SOCIETY, 2023).

### 2.2 Termografia infravermelha

Os seres humanos são homeotérmicos, ou seja, são capazes de manter uma temperatura constante e diferente do ambiente em que se encontram, e isso é fundamental para a sua sobrevivência. Alterações de alguns graus indicam uma disfunção corporal e variações fora dessa faixa podem causar a interrupção de processos químicos considerados essenciais para o corpo (JONES, 1998).

O corpo humano emite radiação infravermelha, que possui comprimentos de onda entre 70nm e 1mm, sendo assim, não visíveis ao olho humano. Portanto, para a captura dessas imagens térmicas são utilizadas câmeras com sensibilidade ao infravermelho, que

convertem a radiação eletromagnética emitida para valores digitais (ETEHADTAVAKOL; NG, 2017). Um exemplo desse tipo de imagem pode ser visto na Figura 1, disponível em *Database For Mastology Research*<sup>1</sup>.




Figura 1 – Imagem termográfica da mama - disponível em *Database For Mastology Research*

Imagens termográficas, na medicina, possuem o objetivo de mostrar a distribuição de temperatura do corpo humano, sendo assim, adequadas para a captura de alterações na perfusão sanguínea, que podem ocorrer devido a fatores como inflamações, angiogênese, entre outros. Com relação ao câncer de mama, quando há a presença de câncer, o tumor causará uma mudança no padrão vascular e, portanto, uma assimetria na distribuição de temperatura entre as mamas que, por outro lado, normalmente indica pacientes saudáveis quando ocorre a simetria nessa distribuição (SCHAEFER; ZÁVISEK; NAKASHIMA, 2009).

A termografia é uma técnica sem contato e não invasiva, ela apenas registra a radiação natural emitida pela pele e, portanto, não possui efeitos nocivos da radiação, permitindo assim o uso dessa técnica por grande quantidade de tempo e por repetidas vezes (LAHIRI et al., 2012).

## 2.3 Aprendizado de máquina

Aprendizado de máquina, do inglês *machine learning* (ML), é uma subclasse da inteligência artificial e refere-se à capacidade de sistemas aprenderem de forma autônoma com base em suas experiências. Utilizando algoritmos de aprendizagem estatística, que

<sup>1</sup> <https://visual.ic.uff.br/dmi/>

possuem a capacidade de aprimorar suas respostas de forma automática, sistemas de ML podem identificar padrões em dados de entrada e produzir saídas com base em seu aprendizado. Além disso, algoritmos de ML podem ser classificados em três diferentes tipos de aprendizado: supervisionado, não supervisionado e por reforço (SHARMA; SHARMA; JINDAL, 2021).

O aprendizado supervisionado requer um conjunto de dados que incluem exemplos de entrada e suas respectivas saídas rotuladas, permitindo ao modelo prever resultados com base em características de entrada. Por outro lado, o aprendizado não supervisionado busca identificar padrões nos dados de entrada sem rótulos pré-existentes. E no aprendizado por reforço, o modelo é orientado por recompensas e aprende por meio de tentativa e erro, agindo em um ambiente definido para alcançar metas, sem a necessidade de pares de entrada e saída (JANIESCH; ZSCHECH; HEINRICH, 2021).

O aprendizado profundo, do inglês *deep learning*, é um método de aprendizado de representação que permite que uma máquina descubra automaticamente as representações necessárias para detecção ou classificação a partir de dados brutos. Essa abordagem é composta por módulos simples, mas não lineares, que transformam a representação de um nível em representações complexas e um pouco mais abstratas. Esse processo de aprendizado hierárquico ajuda a identificar padrões, características e objetos em dados complexos, como imagens, de forma automatizada, eliminando a necessidade de projetar manualmente essas representações por engenheiros humanos (LECUN; BENGIO; HINTON, 2015).

## 2.4 Segmentação de imagem

A segmentação de imagem é um importante campo da visão computacional e do aprendizado de máquina que se concentra em dividir uma imagem em regiões ou grupos de *pixels* que compartilham características semelhantes ou pertencem a objetos distintos. Esse processo é essencial para a compreensão e análise de imagens, pois permite isolar objetos de interesse e identificar padrões visuais, desempenhando um papel fundamental em diversas aplicações, desde a detecção de objetos em imagens médicas até a análise de cenas em veículos autônomos (SZELISKI, 2021).

A tarefa de segmentação de imagens pode ser definida a partir da solução de alguns problemas, como a atribuição de rótulos semânticos a cada *pixel* com base em um conjunto predefinido de categorias, conhecida como segmentação semântica, ou detectando e delineando cada objeto de interesse na imagem, chamada de segmentação por instância, ou até mesmo ambos, chamada de segmentação panóptica (MINAEE et al., 2022). Um exemplo dessas segmentações pode ser visto na Figura 2.

Existem várias abordagens para realizar a segmentação de imagem, incluindo téc-

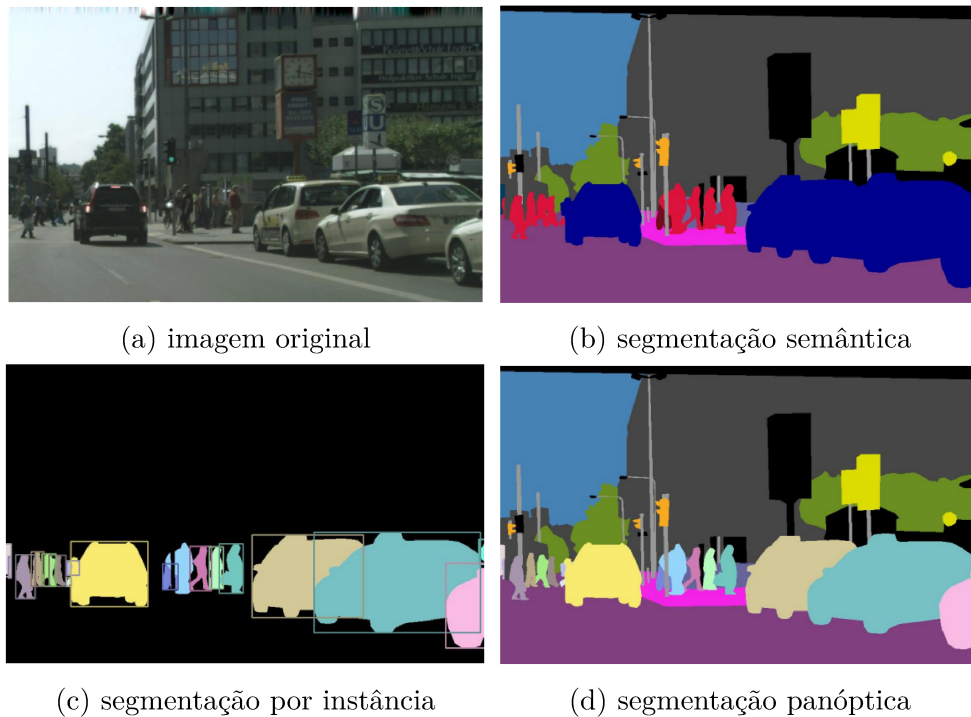


Figura 2 – Exemplo de segmentação de imagem - adaptado de (KIRILLOV et al., 2019)

nicas antigas como divisão de regiões em que a imagem é dividida em partes cada vez mais finas, e fusão de regiões, onde regiões próximas são combinadas com base em critérios específicos. Além disso, algoritmos mais recentes buscam otimizar critérios globais, como a consistência dentro de regiões e as diferenças entre as fronteiras das regiões. A escolha da técnica de segmentação adequada depende das características da imagem e dos objetivos da análise (SZELISKI, 2021).

### 2.4.1 Uso de aprendizado profundo para segmentação de imagem

Nos últimos anos, novos algoritmos para segmentação de imagens surgiram a partir de modelos de aprendizado profundo, apresentando desempenho com melhorias significativas, e alcançando altas taxas de precisão em avaliações amplamente reconhecidas, provocando assim uma transformação significativa no panorama da área (MINAEE et al., 2022).

Uma abordagem poderosa na segmentação de imagens é o uso de algoritmos de aprendizado profundo, como as Redes Neurais Convolucionais (CNNs) com suas operações de convolução. Essa abordagem é amplamente utilizada em diversas aplicações, como reconhecimento de objetos, detecção de bordas, segmentação de regiões de interesse em imagens médicas, entre outras. Ela oferece uma maneira eficaz de automatizar a tarefa de segmentação, permitindo que os sistemas de visão computacional identifiquem áreas de interesse em imagens de forma precisa e eficiente (GHOSH et al., 2019).

## 2.5 Redes Neurais Convolucionais

Redes Neurais Convolucionais (CNNs), ou apenas redes convolucionais, utilizam uma operação matemática chamada convolução, uma forma específica de operação linear utilizada por essas redes, se diferenciando assim das demais redes neurais, que em suas camadas normalmente utilizam multiplicação de matrizes. CNNs são um tipo de rede neural projetadas para processar dados que possuem uma topologia similar a um *grid*, como imagens, que podem ser representadas como um *grid* bidimensional de *pixels* (GOODFELLOW; BENGIO; COURVILLE, 2016).

As CNNs aproveitam três ideias que ajudam a melhorar um sistema de aprendizado de máquina: interações esparsas, compartilhamento de parâmetros e representações equivariantes. Em camadas de redes neurais tradicionais cada unidade de entrada interage com cada unidade de saída, entretanto, CNNs fazem uso de interações esparsas, utilizando *kernels* menores que a entrada. Por exemplo, ao processar uma imagem com milhares de *pixels* é possível detectar características pequenas e significativas, como bordas, usando *kernels* que ocupam apenas centenas de *pixels*. O compartilhamento de parâmetros permite que o mesmo conjunto de parâmetros seja usado para mais de uma função em um modelo, diferente de uma rede tradicional que utiliza cada elemento da matriz de peso exatamente uma vez para calcular a saída de uma camada. A forma particular de compartilhamento de parâmetros faz com que a camada tenha uma propriedade chamada equivariância à tradução, que significa que se uma entrada mudar, a saída mudará do mesmo jeito, e isso possui grande utilidade na detecção de bordas em imagens (GOODFELLOW; BENGIO; COURVILLE, 2016).

Uma camada de uma CNN consiste em três estágios como pode ser visto na Figura 3. O primeiro é responsável por realizar diversas convoluções para produzir um conjunto de ativações lineares. O segundo, às vezes chamado de estágio detector, executa cada uma das ativações lineares utilizando uma função de ativação não linear. No terceiro estágio, uma função *pooling* é utilizada para modificar a saída dessa camada. O *pooling* realiza uma substituição da saída da rede em um determinado local por uma estatística resumida derivada de saídas próximas, e seu uso ajuda a tornar a representação aproximadamente invariante para pequenas traduções da entrada (GOODFELLOW; BENGIO; COURVILLE, 2016).

### 2.5.1 DeepLabV3+

O modelo DeepLabV3+, apresentado na Figura 4, é uma CNN com arquitetura de segmentação semântica proposta por Chen et al. (2018), que estende a DeepLabV3 adicionando uma estrutura de codificação-decodificação. O módulo de codificação é usado para processar informações contextuais valiosas, e um simples módulo para decodificação



é adotado para recuperar os limites do objeto.

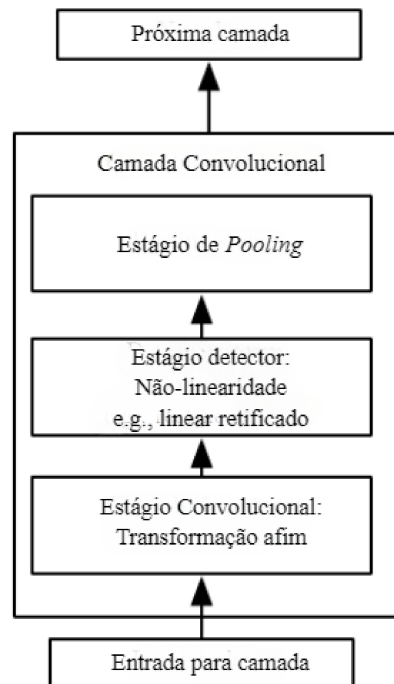


Figura 3 – Estágios de uma camada CNN - adaptado de Goodfellow, Bengio e Courville (2016)

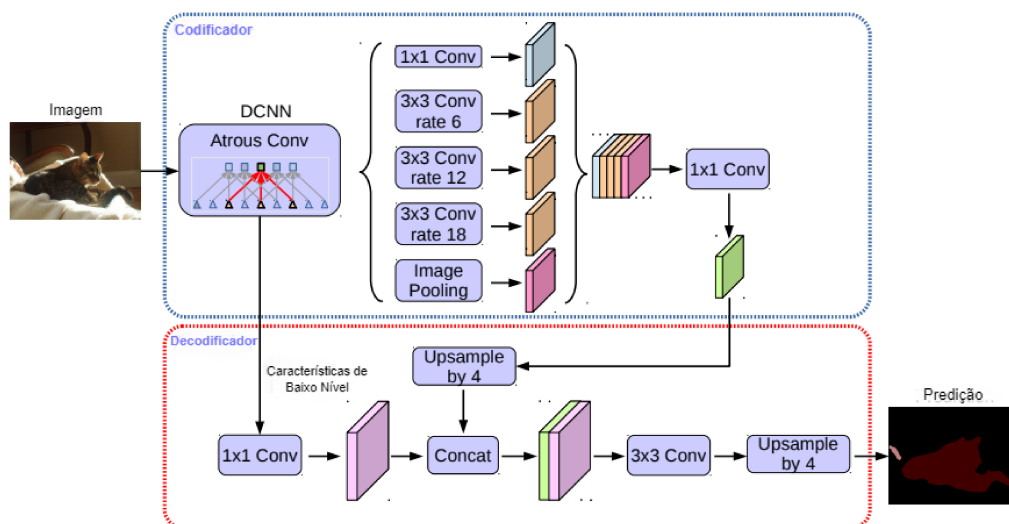


Figura 4 – Modelo DeepLabV3+ proposto por Chen et al. (2018) - adaptado de Chen et al. (2018)

Devido ao *pooling* ou convoluções com deslocamento no *backbone* da rede, mesmo que ricas informações semânticas sejam codificadas no último mapa de características, faltam informações detalhadas sobre os limites dos objetos. Isso pode ser resolvido ao extrair mapa de características mais densos utilizando *atrous convolution*, uma ferramenta que permite o controle explícito da resolução de recursos computados por CNNs profundas,

e o ajuste do campo de visão do filtro para realizar a captura de informações multiescala (CHEN et al., 2018).

A DeepLabV3 usada como codificador implementa a *atrous convolution* para extrair características computadas por CNNs profundas, *backbones*, em uma resolução arbitrária. Então, os autores propõem um decodificador simples, mas efetivo, aplicando uma convolução  $1 \times 1$  nos recursos de baixo nível para reduzir o número de canais, uma vez que os recursos correspondentes de baixo nível geralmente contêm um grande número de canais e dificultam o treinamento. Após a concatenação com os recursos do codificador, são aplicadas algumas convoluções  $3 \times 3$  para refinamento (CHEN et al., 2018).

## 2.5.2 Transferência de aprendizado

A transferência de aprendizado é uma técnica da área de aprendizado de máquina, que permite que um modelo pré-treinado, frequentemente treinado em um conjunto de dados vasto e diversificado como a ImageNet, seja adaptado e refinado para uma tarefa específica, aproveitando o conhecimento previamente adquirido em outra atividade relacionada. Essa abordagem é especialmente útil quando se trabalha com conjuntos de dados menores, pois evita a necessidade de treinar um modelo do zero, economizando tempo (GUPTA; PATHAK; KUMAR, 2022). A transferência de aprendizado baseado em rede sugere que as primeiras camadas de uma rede neural profunda, inicialmente treinadas em um contexto mais amplo, conseguem capturar conhecimentos adaptativos e transferíveis (CHANG et al., 2018).

Em contextos de visão computacional, diferentes redes convolucionais são utilizadas como *backbones* para tarefas específicas, visando a detecção, reconhecimento de objetos e análise de cenas. Esses *backbones* desempenham um papel crucial na melhoria do desempenho, permitindo o processamento de conjuntos de dados em grande escala e a aprendizagem genérica que pode funcionar em diversos ambientes (ELHARROUSS et al., 2022).

### 3 Trabalhos correlatos

Em sua pesquisa, [Zhou, Li e Aggarwal \(2004\)](#) apresentam uma abordagem de conjunto de níveis para realizar a segmentação de imagens térmicas. Os autores apresentam o conceito de mapa de bordas, obtido a partir da exploração de características isotrópicas e lineares dos filtros Gaussianos, para representar a magnitude e direção do gradiente, pois esse mapa aponta para o limite mais próximo e sua magnitude representa a energia total do gradiente no semiplano. Apenas alguns *pixels* iniciais nas imagens térmicas são suficientes para extrair bons limites, localizando o início da evolução e fornecendo informações sobre o gradiente, e adicionar mais *pixels* no início podem reduzir o tempo total de segmentação. Essa abordagem, em comparação ao uso de magnitude de bordas unicamente, apresenta resultados significativamente superiores.

Em [Marques \(2012\)](#), é proposto um método de segmentação das mamas em imagens térmicas, e a metodologia utilizada consiste no uso de diversas técnicas, como limiarização, detecção de contornos, crescimento de regiões, dentre outras. O autor dividiu a segmentação da ROI em três etapas, sendo a primeira a detecção dos contornos laterais, em seguida a obtenção dos limites superiores, e por fim a identificação dos limites inferiores.

Na primeira etapa, utilizando técnicas de limiarização e de derivadas discretas, é feita a remoção do fundo da imagem, separando o corpo da paciente do restante da imagem, e são definidos os contornos do corpo. Em seguida, para a detecção dos limites superiores, primeiro é identificado se a imagem possui braços e pescoço, se não possuir é utilizado o limite da própria imagem, caso contrário, o limite é estabelecido utilizando crescimento de região. Na terceira etapa é encontrada a curva que define a região inframamária, e utilizando técnicas de interpolação de pontos na curva é encontrada a curva que define o limite inferior da ROI. O resultado obtido pelo autor após as três etapas pode ser observado na [Figura 5](#).

Ao final dessas etapas, os resultados de cada uma juntos formam uma imagem que possui apenas as bordas da ROI, e para completar a extração dessa região é realizado um crescimento de região em um ponto superior ao ponto mais elevado da borda inferior. Esse método proposto pelo autor obteve uma acurácia média de 97% e uma sensibilidade média de 97%.

Em [Baffa, Cheloni e Lattari \(2016\)](#), buscando a segmentação automática de imagens termográficas da mama os autores utilizam o conceito de limiarização com refinamento adaptativo, obtendo aproximadamente 96% de acurácia e 98% de sensibilidade. Para isso, criam uma nova técnica, que com base na simetria térmica das imagens, iden-




Figura 5 – Resultado da conjunção de arestas após as três etapas - extraído de Marques (2012)

tifica a região que possivelmente representa as pregas inframamárias. Essa região possui uma maior temperatura devido a sua sobreposição com a parede torácica, facilitando assim sua identificação, e uma vez obtida a região das pregas inframamárias, partem para a próxima etapa que tem como objetivo representar as curvas que compõem as mamas de forma mais fidedigna a partir da moldagem de um polinômio cúbico. O fluxograma desse método descrito pelos autores pode ser visto na Figura 6.

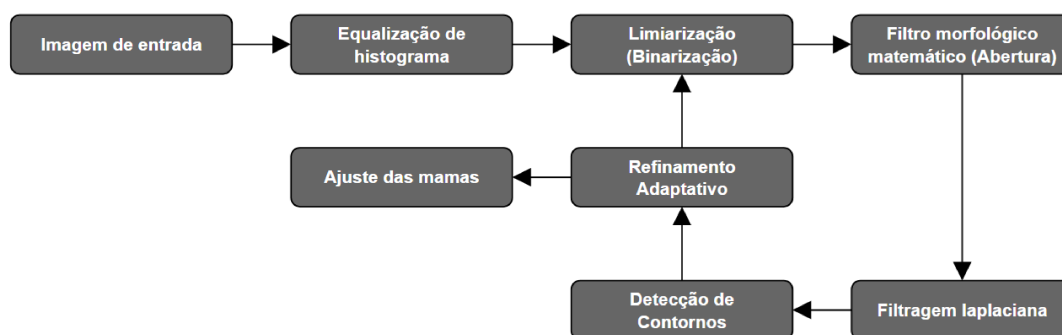


Figura 6 – Fluxograma do método proposto por Baffa, Cheloni e Lattari (2016)

Um estudo realizado por Almajalid et al. (2018), propõe a segmentação de imagens de ultrassom da mama utilizando a rede de aprendizado profundo U-Net. Nessa abordagem, os autores primeiramente modificaram as imagens de entrada incluindo aprimoramentos de redução de ruídos e contraste, após essa primeira etapa é realizado o treinamento na U-Net utilizando técnicas de aumento de dados, como rotação e deformação. Por fim, foi realizado um pós-processamento para a remoção de regiões ruidosas, e como resultado o estudo alcançou um coeficiente DICE de 82,5% e uma taxa de similaridade de 69,8%.

Em Jakhar, Kaur e Gupta (2019) é apresentado um modelo de segmentação de

imagens com objetivo de gerar uma máscara que indique a presença de pneumotórax, uma doença potencialmente fatal, em imagens de radiografia de tórax, auxiliando os médicos na tomada de decisão rápida e precisa. Para isso, os autores utilizam a arquitetura U-Net com ResNet como *backbone*, que possui um bom desempenho em processamento de imagens médicas e segmentação semântica. E ao usar os pesos de rede ResNet pré-treinada ajuda a potencializar o resultado e economiza tempo. O método envolve o pré-processamento das imagens, redimensionamento, normalização e filtragem de ruídos indesejados, e em seguida, é feito o mapeamento da máscara para a imagem original, auxiliando o aprendizado da rede. O modelo proposto alcançou como resultado um coeficiente DICE de 84,3% e IoU de 82,6%. A arquitetura U-Net utilizada pelos autores pode ser observada na Figura 7.

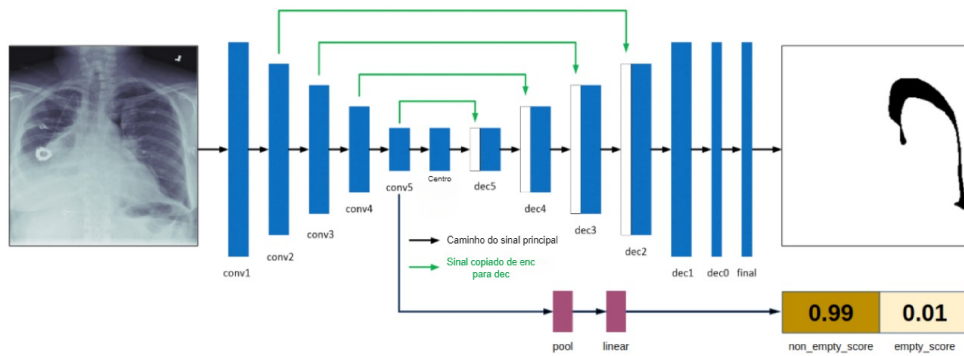


Figura 7 – Arquitetura U-Net utilizada por [Jakhar, Kaur e Gupta \(2019\)](#) - adaptado de [Jakhar, Kaur e Gupta \(2019\)](#)

Em [Choudhury et al. \(2019\)](#) é proposta a utilização da rede DeepLabV3+ para a tarefa de segmentação de tumores cerebrais, com objetivo de identificar todo o tumor, o núcleo do tumor e o núcleo de realce do tumor cerebral. O processo envolve a criação de 6 conjuntos de imagens nas três orientações separadas, coronal, sagital e axial, para criar as entradas dos 18 modelos iniciais. Utilizando um modelo DeepLabV3+ pré-treinado com o conjunto de dados Pascal VOC aumentado, com uma taxa de aprendizado de 0,005, os modelos foram treinados separadamente nos 6 conjuntos de fatias, obtendo assim 3 modelos treinados separados para cada conjunto. As saídas desses 18 classificadores são combinadas usando empacotamento de bits, para preparar as entradas para os três classificadores finais. Durante o treinamento, foram usadas apenas fatias do conjunto de treinamento que possuem tumores, afim de diminuir o desequilíbrio de classes, pois, a parte do cérebro que possui tumores é significativamente menor do que a parte saudável. Os resultados mostram um coeficiente DICE de 0,7086 para o tumor intensificado, 0,7897 para o núcleo do tumor e 0,8755 para todas as regiões do tumor.

Um outro estudo feito por [Baffa, Coelho e Conci \(2021\)](#) propõe um método de segmentação de imagens infravermelhas para detecção do câncer de mama, utilizando Redes Neurais Convolucionais U-Net. Essas redes possuem como característica a alta

eficiência e robustez na construção de máscaras de segmentação de imagens biomédicas. Com base nessa abordagem, os pesquisadores, utilizando a U-Net, desenvolveram um algoritmo para a segmentação automática aplicada a imagens médicas. Como resultados obtidos, esse trabalho apresentou uma acurácia média de 98,24%, IoU de 94,38% e precisão de 98,86%.

## 4 Desenvolvimento

Neste capítulo será apresentada a base de dados utilizada nesse trabalho, as métricas escolhidas para avaliação do modelo proposto, a técnica de aumento de dados para diversificar os dados, e o processo para realização do treinamento e teste. Um diagrama contendo todas as etapas da abordagem proposta neste trabalho pode ser visto na Figura 8.

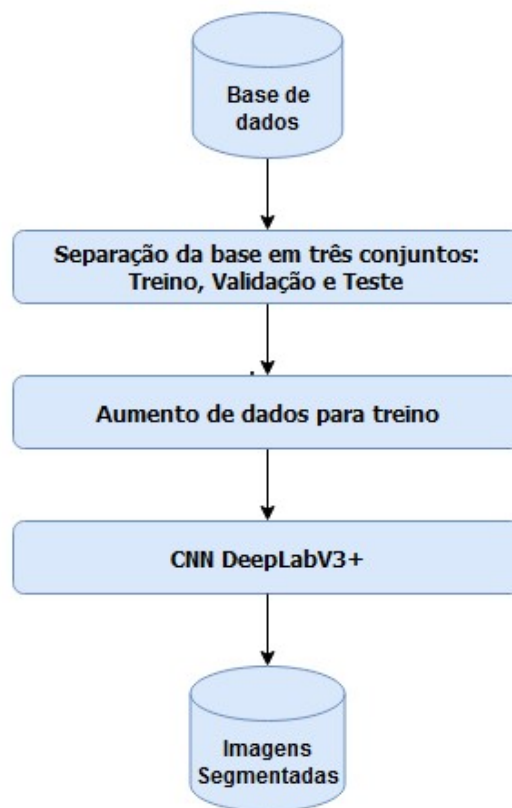


Figura 8 – Diagrama das etapas da abordagem

### 4.1 Base de Dados

A base de dados utilizada foi proposta por Marques (2012) e está disponível online <sup>1</sup>. Esta base é composta por um total de 283 imagens termográficas da mama e cada uma dessas imagens é acompanhada por seus respectivos *ground truths*, que representa a máscara de segmentação esperada como resultado. Apesar da base de dados *Database For Mastology Research* possuir um número maior de pacientes, optou-se pela base apresentada em Marques (2012) por ela já estar rotulada.

<sup>1</sup> <http://visual.ic.uff.br/proeng/marques/download.php>

Uma representação visual das distintas posições que podem ser utilizadas na captura das imagens termográficas pode ser observada na Figura 9. E cada uma pode ser definida da seguinte forma:

- **T1**: Captura frontal em que a paciente se encontra com as mãos na cintura.
- **T2**: Captura frontal em que a paciente se encontra com os braços para cima.
- **MD e ME**: Captura frontal individual de cada mama, direita e esquerda, respectivamente.
- **LEMD e LEME**: Captura lateral externa de cada mama, direita e esquerda, respectivamente.
- **LIMD e LIME**: Captura lateral interna de cada mama, direita e esquerda, respectivamente.

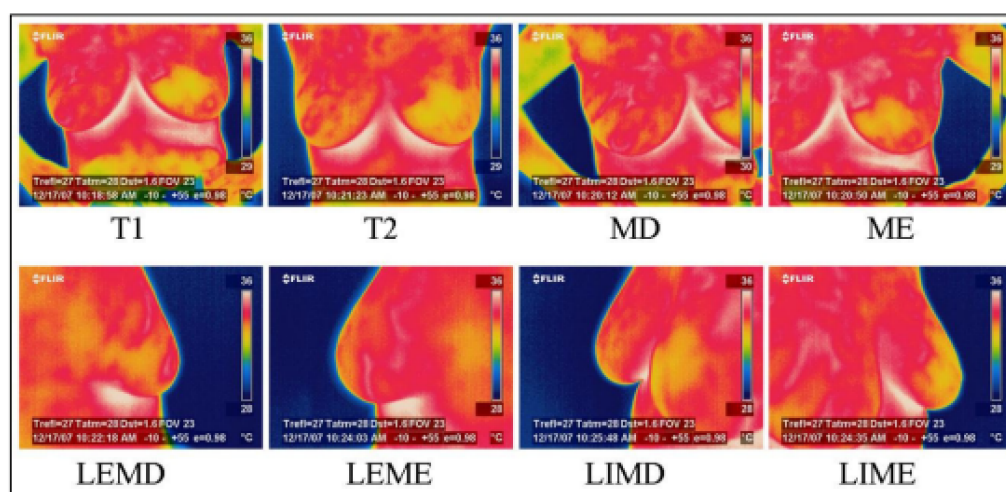


Figura 9 – Posições para captura das imagens - extraído de [Motta \(2010\)](#)


Dentre as oito posições disponíveis, [Marques \(2012\)](#) optou por utilizar a posição T2. Esta escolha se justifica pelo fato de que a posição escolhida abrange a região axilar como área de interesse, adquirindo assim um maior número de informações relevantes.

No que diz respeito às características das imagens termográficas, que são imagens em pseudo-cor geradas a partir de uma matriz de temperaturas, elas foram adquiridas utilizando a câmera FLIR Thermancan S45 e possuem 320x240 *pixels* de dimensão. Para essa base, o autor propôs uma transformação da matriz de temperaturas para uma escala de 256 tons de cinza, então, a temperatura mais baixa detectada é representada como 0 (preto), enquanto a temperatura mais alta é representada como 255 (branco), e todos os outros valores são ajustados para caber nesse intervalo de 0 a 255.



O *ground truth* associado a cada imagem foi obtido por meio de um método de segmentação manual conduzido por um especialista na área, que utilizou um software denominado GTMaker para realizar esse processo minucioso.

Para proporcionar uma melhor compreensão da natureza das imagens termográficas incluídas na base de dados, pode-se observar na Figura 10a imagens termográficas extraídas desta coleção. Concomitantemente, na Figura 10b é possível observar a máscara de segmentação correspondente, a qual delinea a região de interesse na imagem termográfica.



(a) Imagem original em escala de tons de cinza

(b) Respectiva máscara de segmentação criada por especialista

Figura 10 – Exemplo extraído da base de dados

## 4.2 Métricas de avaliação

A avaliação das segmentações obtidas é de fundamental importância para determinar a qualidade e eficácia do modelo. Portanto, serão utilizadas as seguintes métricas: acurácia, interseção pela união e precisão.

Para esse trabalho, cada *pixel* da imagem, que será introduzido na rede, será classificado como pertencente ou não à região de interesse da mama. Deste modo, baseados nessa classificação, são apresentados alguns conceitos, sendo eles:

- **Verdadeiro Positivo (VP):** *Pixels* que foram corretamente classificados como pertencentes à região de interesse.
- **Falso Positivo (FP):** *Pixels* que foram erroneamente classificados como pertencentes à região de interesse quando, na verdade, não pertencem.
- **Falso Negativo (FN):** *Pixels* que foram erroneamente classificados como não pertencentes à região de interesse quando, na verdade, pertencem.
- **Verdadeiro Negativo (VN):** *Pixels* que foram corretamente classificados como não pertencentes à região de interesse.

Então, as métricas citadas anteriormente são apresentadas a seguir:

- **Acurácia:** Essa métrica mede a proporção de *pixels* corretamente classificados em relação ao total de *pixels* na imagem. A Equação 4.1 mostra como essa métrica é calculada:

$$Acurácia = \frac{VP + VN}{VP + FP + FN + VN} \quad (4.1)$$

- **Interseção pela União (IoU):** Essa métrica mede a sobreposição entre a máscara de segmentação obtida pelo modelo e o *ground truth*. Ela é calculada pela divisão da área da interseção entre as duas segmentações pela área da união delas. A Equação 4.2 mostra como essa métrica é calculada:

$$IoU = \frac{Interseção}{União} \quad (4.2)$$

- **Precisão:** Uma métrica que se concentra na proporção de *pixels* corretamente classificados como positivos em relação a todos os *pixels* classificados como positivos pelo modelo. A Equação 4.3 mostra como essa métrica é calculada:

$$Precisão = \frac{VP}{VP + FP} \quad (4.3)$$

### 4.3 Aumento de dados

Aumento de dados, do inglês *data augmentation*, é uma técnica empregada no campo de aprendizado de máquina, com o objetivo de enriquecer a variabilidade do conjunto de dados utilizado. Na área de visão computacional, essa técnica é empregada para mitigar o problema de *overfitting* em Redes Neurais Convolucionais, aplicando transformações nas imagens, capacitando o modelo para lidar com variações naturais nos dados.

O ajuste excessivo, do inglês *overfitting*, em uma CNN se manifesta quando o modelo demonstra um ótimo desempenho em dados de treinamento, mas não consegue produzir previsões igualmente precisas em novos dados, indicando uma incapacidade de generalização.

Dentre as possíveis transformações às imagens podem incluir rotações, ampliações, recortes, espelhamentos horizontais e verticais, ajustes de brilho, e até mesmo a aplicação de filtros de desfoque, entre outras possibilidades.

Para esse trabalho, que utiliza imagens médicas de termografia infravermelha obtidas em um ambiente controlado, optou-se por aplicar a rotação das imagens em ângulos entre 10 e 20 graus, uma escolha que se alinha com as variações esperadas. Um exemplo de aplicação dessa transformação pode ser visto na Figura 11.




Figura 11 – Exemplo de aplicação da rotação

## 4.4 Segmentação

O conjunto de imagens utilizado nesse trabalho será dividido em três partes. Essa divisão possui como objetivo preparar o ambiente para um treinamento eficaz e uma avaliação justa do desempenho da rede.

A primeira parte do conjunto, correspondente a 70% do total, será reservada para o treinamento. Portanto, essas imagens serão usadas para treinar a rede a reconhecer padrões e características nas imagens termográficas.

A segunda parte, composta por 10% das imagens, irá formar o conjunto de validação. Ele é usado para evitar o *overfitting*, servindo de auxílio para que a rede não memorize as imagens de treinamento.

Por fim, os 20% restantes das imagens serão reservados para teste. Essas imagens não foram usadas em nenhuma etapa anterior do processo de treinamento, garantindo uma avaliação imparcial do desempenho, e isso permite verificar o quão bem a rede generaliza para imagens novas e desconhecidas.

Quanto ao tipo de aprendizado de máquina utilizado neste trabalho, é empregado o aprendizado supervisionado, pois a base de dados inclui imagens termográficas juntamente com suas máscaras de segmentação correspondentes. Então, para o treinamento são apresentadas as imagens e seus *ground truths*, permitindo que a rede aprenda observando as correspondências entre as entradas e as saídas esperadas.

Para a tarefa de segmentação, foi utilizado a arquitetura de CNN conhecida como DeepLabV3+, fazendo uso de uma rede Resnet-101 pré-treinada com a base de dados ImageNet como seu *backbone*. Essa escolha se justifica pela capacidade dessa arquitetura em realizar segmentação semântica, que é a tarefa em questão, pois envolve a classificação de cada pixel na imagem em pertencente ou não à região de interesse da mama.

## 5 Resultados e Discussão

Para a realização dos experimentos, empregou-se a linguagem Python. Adotou-se o otimizador Adam, com uma taxa de aprendizado de 0,0001. Além disso, optou-se por utilizar a plataforma Google Colab, que disponibiliza um ambiente de execução equipado com GPU. Toda a implementação realizada neste trabalho de conclusão está disponível online <sup>1</sup>.

Os resultados foram derivados de 10 execuções do experimento, nas quais os valores das métricas de avaliação foram registrados. O treinamento foi conduzido por 30 épocas, pois demonstrou estabilidade da rede, o que não ocorre com uma quantidade menor de épocas, e também, evita o *overfitting*, que pode ocorrer com treinamentos de maior duração. É possível observar na Tabela 1 os valores de acurácia, IoU e precisão para cada uma das 10 execuções individuais, e representando o resultado final a ser considerado, será feita a média das métricas nessas execuções.

<b>Execução</b>	<b>Acurácia</b>	<b>IoU</b>	<b>Precisão</b>
1	0,9873	0,9725	0,9851
2	0,9872	0,9723	0,9846
3	0,9866	0,9712	0,9841
4	0,9872	0,9724	0,9875
5	0,9870	0,9720	0,9847
6	0,9866	0,9711	0,9833
7	0,9868	0,9715	0,9858
8	0,9862	0,9704	0,9839
9	0,9877	0,9734	0,9845
10	0,9866	0,9712	0,9846

Tabela 1 – Resultados dos dados de teste de cada execução com 30 épocas

Os valores obtidos em cada uma das 10 execuções foram adquiridos por meio da aplicação da rede nos dados de teste, pois esses dados não possuem qualquer ligação com o processo de treinamento, e possibilitam avaliar o quão bem a rede é capaz de generalizar seu aprendizado.

Baffa, Coelho e Conci (2021), que utilizaram um método de segmentação baseado em CNNs U-Net, obtiveram médias de acurácia de 98,24%, IoU de 94,38% e precisão de 98,86%. O presente estudo, apresentando a proposta de utilizar um método de segmentação baseado na rede DeepLabV3+, obteve resultados ligeiramente melhores, nos quais a acurácia média foi de 98,69%, IoU de 97,18% e precisão de 98,48%.

<sup>1</sup> <https://github.com/TiagoTHS/breast-thermal-images-segmentation>

Uma representação visual dos resultados obtidos pela melhor execução, dentre as 10, do experimento, pode ser vista na Figura 12. Na Figura 12a é possível observar imagens termográficas originais da base de dados em tons de cinza, enquanto na Figura 12b podem ser vistos os *ground truths* correspondentes, elaborados por especialistas. Por fim, as máscaras de segmentações geradas pelo método proposto podem ser observadas na Figura 12c.

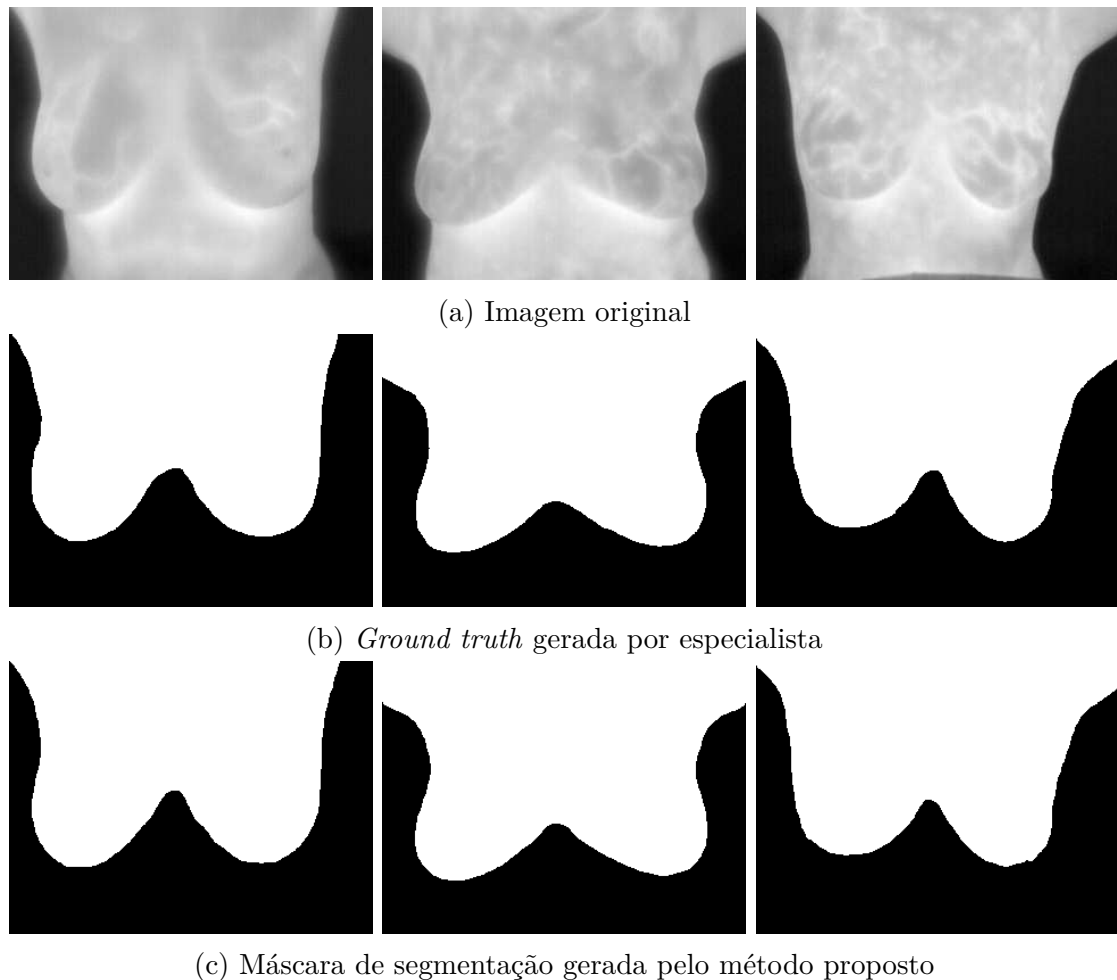


Figura 12 – Resultados obtidos na melhor execução do experimento

Analisando os resultados das métricas e comparando os *ground truths* com as máscaras de segmentação geradas, é evidente que o algoritmo empregado obteve um bom desempenho na tarefa de segmentação. Porém, foram observadas algumas deficiências, por exemplo, quando o pescoço da paciente foi segmentado de forma incorreta, e pequenos detalhes, como partes do cabelo, foram incorretamente incluídos na máscara de segmentação. Essas imperfeições, ilustradas na Figura 13, destacam desafios enfrentados pelo algoritmo.

Além das limitações observadas nas segmentações, outro fator que pode ter prejudicado o treinamento foi o fato do banco utilizado possuir somente 283 imagens. Essa baixa quantidade de imagens disponíveis para treinamento e teste do algoritmo, um pro-

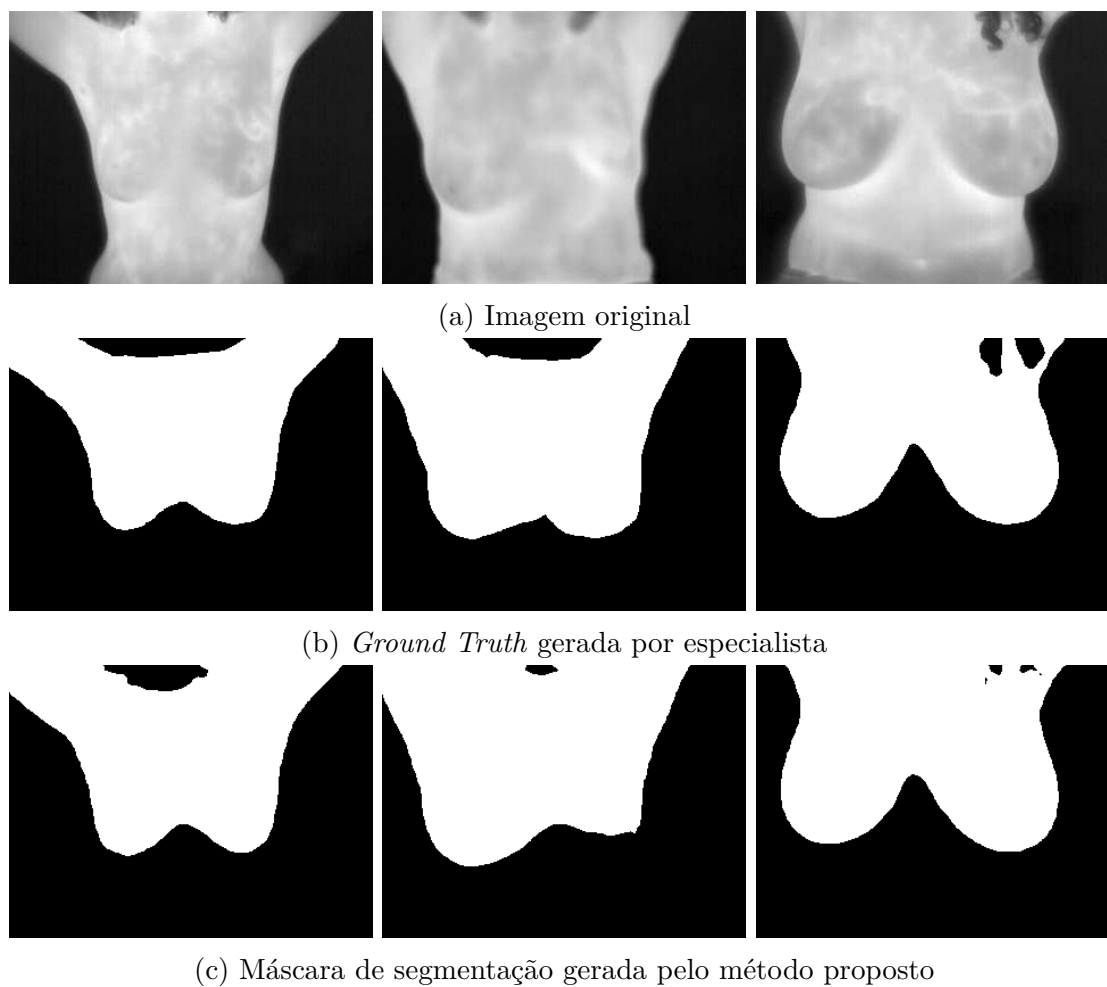


Figura 13 – Imperfeições percebidas na melhor execução do experimento

blema amplamente conhecido na área de treinamento de redes profundas, certamente comprometeu a capacidade da rede de aprender os padrões necessários.

## 6 Conclusão

A segmentação automática de região de interesse em imagens termográficas da mama é uma importante tarefa que colabora no desenvolvimento de classificadores que possuem como objetivo a detecção do câncer de mama.

No desenvolvimento deste estudo, foi utilizada uma arquitetura de Rede Neural Convolutiva pré-treinada, a DeepLabV3+, com uma Resnet-101 como *backbone*, com o objetivo de realizar a segmentação de região de interesse em imagens termográficas da mama, removendo dessas imagens algumas partes que podem ser consideradas como ruídos, tal como o plano de fundo, tórax, entre outros. A base de dados utilizada é composta por 283 imagens termográficas da mama, cada uma com seus respectivos *ground truths*, e esses dados foram separados em conjuntos de treinamento, validação e teste, para uma avaliação justa do desempenho do algoritmo.

Foram realizadas 10 execuções do experimento, cada uma com um treinamento de 30 épocas, cuja média das métricas de acurácia, IoU e precisão obtidas em cada execução foi calculada como o resultado final. Os resultados revelaram uma acurácia de 98,69%, IoU de 97,18% e precisão de 98,48%, sugerindo a capacidade promissora do algoritmo. No entanto, é preciso considerar alguns aspectos ao avaliar esses resultados, como a falha ao segmentar detalhes específicos nas imagens, como o pescoço e o cabelo da paciente, e também a reduzida quantidade de imagens disponíveis na base de dados utilizada no estudo.

Algumas disciplinas do curso de Ciência da Computação apresentaram grande contribuição para o desenvolvimento deste trabalho, como inteligência computacional, que expôs o conhecimento sobre redes neurais convolucionais e o processo de treinamento dessas redes, e inteligência artificial, que ajudou a entender os diferentes tipos de aprendizado de máquina.

Em futuras pesquisas, este estudo pode ser utilizado para segmentar regiões de interesse em imagens termográficas da mama, que serão aplicadas em um classificador para a detecção do câncer de mama, visando uma classificação mais apurada. Além disso, pode-se realizar a comparação de diferentes arquiteturas de CNNs na execução da tarefa de segmentação de imagens termográficas da mama. Outra opção é a utilização de um modelo híbrido para essa tarefa, combinando técnicas tradicionais de processamento digital de imagens com redes convolucionais.



## Referências

- ACHARYA, U. R.; NG, E. Y.; TAN, J. H.; SREE, S. V. Thermography based breast cancer detection using texture features and support vector machine. **Journal of Medical Systems**, v. 36, 2012. ISSN 01485598. Disponível em: <<https://doi.org/10.1007/s10916-010-9611-z>>. Citado na página 9.
- ALMAJALID, R.; SHAN, J.; DU, Y.; ZHANG, M. Development of a deep-learning-based method for breast ultrasound image segmentation. In: **IEEE. 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)**. Orlando, FL, USA, 2018. p. 1103–1108. Disponível em: <<https://doi.org/10.1109/ICMLA.2018.00179>>. Citado na página 19.
- BAFFA, M.; CHELONI, D.; LATTARI, L. Segmentação automática de imagens térmicas das mamas utilizando limiarização com refinamento adaptativo. In: **Anais do XVI Workshop de Informática Médica**. Porto Alegre, RS, Brasil: SBC, 2016. p. 2499–2508. ISSN 2763-8952. Disponível em: <<https://doi.org/10.5753/sbcas.2016.9896>>. Citado 3 vezes nas páginas 5, 18 e 19.
- BAFFA, M.; COELHO, A.; CONCI, A. Segmentação de imagens infravermelhas para detecção do câncer de mama utilizando u-net cnn. In: **Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde**. Porto Alegre, RS, Brasil: SBC, 2021. p. 119–128. ISSN 2763-8952. Disponível em: <<https://doi.org/10.5753/sbcas.2021.16058>>. Citado 2 vezes nas páginas 20 e 28.
- BAFFA, M. de F. O.; LATTARI, L. G. Convolutional neural networks for static and dynamic breast infrared imaging classification. In: **2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)**. Los Alamitos, CA, USA: IEEE Computer Society, 2018. p. 174–181. Disponível em: <<https://www.doi.org/10.1109/SIBGRAPI.2018.00029>>. Citado na página 9.
- BERNARDES, N. B.; SÁ, A. C. F. de; FACIOLI, L. de S.; FERREIRA, M. L.; SÁ, O. R. de; COSTA, R. de M. Câncer de mama x diagnóstico/breast cancer x diagnosis. **ID on line. Revista de psicologia**, v. 13, n. 44, p. 877–885, 2019. Disponível em: <<https://doi.org/10.14295/idonline.v13i44.1636>>. Citado na página 11.
- BORCHARTT, T. B.; CONCI, A.; LIMA, R. C.; RESMINI, R.; SANCHEZ, A. Breast thermography from an image processing viewpoint: A survey. **Signal Processing**, v. 93, n. 10, p. 2785–2803, 2013. ISSN 0165-1684. Signal and Image Processing Techniques for Detection of Breast Diseases. Disponível em: <<https://doi.org/10.1016/j.sigpro.2012.08.012>>. Citado 2 vezes nas páginas 10 e 11.
- CHANG, H.; HAN, J.; ZHONG, C.; SNIJDERS, A. M.; MAO, J.-H. Unsupervised transfer learning via multi-scale convolutional sparse coding for biomedical applications. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 40, n. 5, p. 1182–1194, 2018. Disponível em: <<https://doi.org/10.1109/TPAMI.2017.2656884>>. Citado na página 17.

- CHEN, L.-C.; ZHU, Y.; PAPANDREOU, G.; SCHROFF, F.; ADAM, H. Encoder-decoder with atrous separable convolution for semantic image segmentation. In: FERRARI, V.; HEBERT, M.; SMINCHISESCU, C.; WEISS, Y. (Ed.). **Computer Vision – ECCV 2018**. Cham: Springer International Publishing, 2018. v. 11211 LNCS, p. 833–851. ISBN 978-3-030-01234-2. ISSN 16113349. Disponível em: <[https://www.doi.org/10.1007/978-3-030-01234-2\\_49](https://www.doi.org/10.1007/978-3-030-01234-2_49)>. Citado 4 vezes nas páginas 5, 15, 16 e 17.
- CHOUDHURY, A. R.; VANGURI, R.; JAMBAWALIKAR, S. R.; KUMAR, P. Segmentation of brain tumors using deeplabv3+. In: **Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries**. Cham: Springer International Publishing, 2019. p. 154–167. ISBN 978-3-030-11726-9. Disponível em: <[https://doi.org/10.1007/978-3-030-11726-9\\_14](https://doi.org/10.1007/978-3-030-11726-9_14)>. Citado na página 20.
- ELHARROUSS, O.; AKBARI, Y.; ALMAADEED, N.; AL-MAADEED, S. **Backbones-Review: Feature Extraction Networks for Deep Learning and Deep Reinforcement Learning Approaches**. 2022. Disponível em: <<https://doi.org/10.48550/arXiv.2206.08016>>. Citado na página 17.
- ETEHADTAVAKOL, M.; NG, E. Y. K. An overview of medical infrared imaging in breast abnormalities detection. In: \_\_\_\_\_. **Application of Infrared to Biomedical Sciences**. Singapore: Springer Singapore, 2017. p. 45–57. ISBN 978-981-10-3147-2. Disponível em: <[https://doi.org/10.1007/978-981-10-3147-2\\_4](https://doi.org/10.1007/978-981-10-3147-2_4)>. Citado na página 12.
- GHOSH, S.; DAS, N.; DAS, I.; MAULIK, U. Understanding deep learning techniques for image segmentation. **ACM Comput. Surv.**, Association for Computing Machinery, New York, NY, USA, v. 52, n. 4, aug 2019. ISSN 0360-0300. Disponível em: <<https://doi.org/10.1145/3329784>>. Citado na página 14.
- 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.n.], 2021. p. 101–106. Disponível em: <<https://doi.org/10.1109/CBMS52027.2021.00094>>. Citado na página 9.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Online: MIT Press, 2016. <<http://www.deeplearningbook.org>>. ISBN 978-0262035613. Citado 3 vezes nas páginas 5, 15 e 16.
- GUPTA, J.; PATHAK, S.; KUMAR, G. Deep learning (cnn) and transfer learning: A review. **Journal of Physics: Conference Series**, IOP Publishing, v. 2273, n. 1, p. 012029, may 2022. Disponível em: <<https://doi.org/10.1088/1742-6596/2273/1/012029>>. Citado na página 17.
- INCA, I. N. do C. **Estatísticas de câncer**. 2022. Disponível em: <<https://www.gov.br/inca/pt-br/assuntos/cancer/numeros>>. Acesso em: 2023-10-23. Citado na página 9.
- JAKHAR, K.; KAUR, A.; GUPTA, D. M. Pneumothorax segmentation: deep learning image segmentation to predict pneumothorax. **arXiv e-prints**, 2019. Disponível em: <<https://doi.org/10.48550/arXiv.1912.07329>>. Citado 3 vezes nas páginas 5, 19 e 20.

- JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, Springer, v. 31, n. 3, p. 685–695, 2021. Disponível em: <<https://doi.org/10.1007/s12525-021-00475-2>>. Citado na página 13.
- JONES, B. A reappraisal of the use of infrared thermal image analysis in medicine. **IEEE Transactions on Medical Imaging**, v. 17, n. 6, p. 1019–1027, 1998. Disponível em: <<https://www.doi.org/10.1109/42.746635>>. Citado na página 11.
- KIRILLOV, A.; HE, K.; GIRSHICK, R.; ROTHER, C.; DOLLÁR, P. Panoptic segmentation. In: **2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)**. IEEE, 2019. p. 9396–9405. ISSN 10636919. Disponível em: <<https://doi.org/10.1109/CVPR.2019.00963>>. Citado 2 vezes nas páginas 5 e 14.
- LAHIRI, B.; BAGAVATHIAPPAN, S.; JAYAKUMAR, T.; PHILIP, J. Medical applications of infrared thermography: A review. **Infrared Physics & Technology**, v. 55, n. 4, p. 221–235, 2012. ISSN 1350-4495. Disponível em: <<https://doi.org/10.1016/j.infrared.2012.03.007>>. Citado na página 12.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015. Disponível em: <<https://doi.org/10.1038/nature14539>>. Citado na página 13.
- MARQUES, R. de S. **Segmentação Automática das mamas em imagens térmicas**. Dissertação (Mestrado) — Instituto de Computação, Universidade Federal Fluminense, Niterói, RJ, Brasil, 2012. Citado 5 vezes nas páginas 5, 18, 19, 22 e 23.
- MARTÍN, M.; HERRERO, A.; ECHAVARRÍA, I. El cáncer de mama. **Arbor**, v. 191, n. 773, p. a234, jun. 2015. Disponível em: <<https://doi.org/10.3989/arbor.2015.773n3004>>. Citado na página 11.
- MINAEE, S.; BOYKOV, Y.; PORIKLI, F.; PLAZA, A.; KEHTARNAVAZ, N.; TERZOPOULOS, D. Image segmentation using deep learning: A survey. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 44, n. 7, p. 3523–3542, 2022. Disponível em: <<https://doi.org/10.1109/TPAMI.2021.3059968>>. Citado 2 vezes nas páginas 13 e 14.
- MOTTA, L. S. **Obtenção automática da região de interesse em termogramas frontais da mama para o auxílio a detecção precoce de doenças**. Dissertação (Mestrado) — Instituto de Computação, Universidade Federal Fluminense, Niterói, RJ, Brasil, 2010. Citado 3 vezes nas páginas 5, 10 e 23.
- PRAMANIK, R.; PRAMANIK, P.; SARKAR, R. Breast cancer detection in thermograms using a hybrid of ga and gwo based deep feature selection method. **Expert Systems with Applications**, v. 219, p. 119643, 2023. ISSN 0957-4174. Disponível em: <<https://doi.org/10.1016/j.eswa.2023.119643>>. Citado na página 9.
- SCHAEFER, G.; ZÁVIŠEK, M.; NAKASHIMA, T. Thermography based breast cancer analysis using statistical features and fuzzy classification. **Pattern Recognition**, v. 42, n. 6, p. 1133–1137, 2009. ISSN 0031-3203. Digital Image Processing and Pattern Recognition Techniques for the Detection of Cancer. Disponível em: <<https://doi.org/10.1016/j.patcog.2008.08.007>>. Citado na página 12.

- SHARMA, N.; SHARMA, R.; JINDAL, N. Machine learning and deep learning applications-a vision. **Global Transitions Proceedings**, v. 2, n. 1, p. 24–28, 2021. ISSN 2666-285X. 1st International Conference on Advances in Information, Computing and Trends in Data Engineering (AICDE - 2020). Disponível em: <<https://doi.org/10.1016/j.gltp.2021.01.004>>. Citado na página 13.
- SOCIETY, A. C. **American cancer society recommendations for the early detection of breast cancer**. American Cancer Society, 2022. Disponível em: <<https://www.cancer.org/cancer/breast-cancer/screening-tests-and-early-detection/american-cancer-society-recommendations-for-the-early-detection-of-breast-cancer.html>>. Acesso em: 2023-04-17. Citado na página 10.
- \_\_\_\_\_. **Breast Density and Your Mammogram Report**. American Cancer Society, 2023. Disponível em: <<https://www.cancer.org/cancer/types/breast-cancer/screening-tests-and-early-detection/mammograms/breast-density-and-your-mammogram-report.html>>. Acesso em: 2023-05-23. Citado na página 11.
- SZELISKI, R. **Computer Vision : Algorithms and Applications 2nd Edition**. Springer Cham, 2021. ISBN 978-3-030-34372-9. Disponível em: <<https://doi.org/10.1007/978-3-030-34372-9>>. Citado 3 vezes nas páginas 9, 13 e 14.
- THOMAZ, D. **Só um em cada cinco municípios do Brasil tem equipamentos de mamografia**. 2020. Disponível em: <<https://oglobo.globo.com/epoca/brasil/so-um-em-cada-cinco-municipios-do-brasil-tem-equipamentos-de-mamografia-24197793>>. Acesso em: 2023-10-25. Citado na página 9.
- ZHOU, Q.; LI, Z.; AGGARWAL, J. K. Boundary extraction in thermal images by edge map. In: **Proceedings of the 2004 ACM Symposium on Applied Computing**. New York, NY, USA: Association for Computing Machinery, 2004. (SAC '04), p. 254–258. ISBN 1581138121. Disponível em: <<https://doi.org/10.1145/967900.967956>>. Citado 2 vezes nas páginas 10 e 18.
- ZULUAGA-GOMEZ, J.; MASRY, Z. A.; BENAGGOUNE, K.; MERAGHNI, S.; ZERHOUNI, N. A cnn-based methodology for breast cancer diagnosis using thermal images. **Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization**, Taylor & Francis, v. 9, n. 2, p. 131–145, 2021. Disponível em: <<https://doi.org/10.1080/21681163.2020.1824685>>. Citado na página 9.