

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**JULIANA MOREIRA ALVES**

**SEGMENTAÇÃO E CLASSIFICAÇÃO EXPERIMENTAL DE LESÕES  
MAMOGRAFICAS COM REDES NEURAI CONVOLUCIONAIS**

**CAMPO MOURÃO  
2026**

**JULIANA MOREIRA ALVES**

**SEGMENTAÇÃO E CLASSIFICAÇÃO EXPERIMENTAL DE LESÕES  
MAMOGRAFICAS COM REDES NEURAI CONVOLUCIONAIS**

**Experimental segmentation and classification of mammographic  
lesions using convolutional neural networks**

Trabalho de Conclusão de Curso de Graduação  
apresentado como requisito para obtenção do  
título de Bacharel em Engenharia Eletrônica  
da Universidade Tecnológica Federal do Paraná  
(UTFPR).

Orientador: Prof. Dr. Márcio Rodrigues da  
Cunha

**CAMPO MOURÃO  
2026**



4.0 Internacional

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

**JULIANA MOREIRA ALVES**

**SEGMENTAÇÃO E CLASSIFICAÇÃO EXPERIMENTAL DE LESÕES  
MAMOGRAFICAS COM REDES NEURAIS CONVOLUCIONAIS**

Trabalho de Conclusão de Curso de Graduação  
apresentado como requisito para obtenção do  
título de Bacharel em Engenharia Eletrônica  
da Universidade Tecnológica Federal do Paraná  
(UTFPR).

Data de aprovação: 22/06/2026

---

Márcio Rodrigues da Cunha  
Doutorado em Engenharia Elétrica  
Universidade Tecnológica Federal do Paraná

---

Osmar Tormena Junior  
Doutorado em Engenharia Elétrica  
Universidade Tecnológica Federal do Paraná

---

Pamela De Souza Schiaber  
Doutorado em Engenharia Elétrica  
Universidade Tecnológica Federal do Paraná

**CAMPO MOURÃO**  
**2026**

# Agradecimentos

Agradeço primeiramente a Deus, por me dar força, saúde e perseverança ao longo desta caminhada.

Agradeço aos meus pais, pelo apoio, incentivo e compreensão em todos os momentos da minha formação. O suporte da minha família foi essencial para que eu pudesse chegar até aqui.

Agradeço ao meu orientador, Prof. Dr. Márcio Rodrigues da Cunha, pela orientação, disponibilidade e contribuições durante o desenvolvimento deste trabalho e ao longo de toda a graduação.

Agradeço também aos professores do curso de Engenharia Eletrônica da Universidade Tecnológica Federal do Paraná, pelos ensinamentos compartilhados.

Por fim, agradeço aos colegas e amigos que, direta ou indiretamente, contribuíram para esta etapa, seja por meio de apoio, incentivo ou troca de conhecimentos.

# Resumo

Este trabalho teve como objetivo desenvolver uma aplicação em Python para segmentação e classificação experimental de lesões mamográficas utilizando CNNs. Para isso, foi utilizada a base CBIS-DDSM, composta por imagens mamográficas, informações patológicas e anotações de ROI. A metodologia foi dividida em duas etapas principais: segmentação de regiões suspeitas por meio da U-Net e classificação das lesões em benignas ou malignas com modelos baseados em Transfer Learning. Na etapa de segmentação, foram utilizadas mamografias associadas às respectivas máscaras ROI, permitindo o treinamento supervisionado da U-Net. Após a predição da máscara, foi aplicada uma etapa de pós-processamento para remoção de ruídos, preenchimento de falhas e destaque visual da região suspeita. Na etapa de classificação, foram testadas abordagens com CNN inicial, MobileNetV2 e EfficientNetB0. O ajuste do limiar de decisão para a classe maligna permitiu aumentar o recall dessa classe, priorizando a identificação de casos malignos. Os resultados mostraram que a segmentação ainda apresenta limitações, com Dice de validação igual a 0,2459 e IoU de validação igual a 0,1453. Na classificação, o modelo EfficientNetB0 com limiar de 0,20 apresentou recall de 0,71 para a classe maligna, embora com aumento de falsos positivos. A aplicação desenvolvida permitiu integrar segmentação, pós-processamento, classificação e salvamento automático dos resultados. Conclui-se que o sistema possui caráter acadêmico e experimental, não sendo adequado para uso clínico, mas demonstrando o potencial das CNNs no processamento de imagens mamográficas.

**Palavras-chave:** aprendizado profundo; visão computacional; CBIS-DDSM; U-Net; Transfer Learning; processamento de imagens médicas.

# Abstract

This work aimed to develop a Python application for the segmentation and experimental classification of mammographic lesions using CNNs. The CBIS-DDSM database was used, containing mammographic images, pathological information, and ROI annotations. The methodology was divided into two main stages: segmentation of suspicious regions using U-Net and classification of lesions as benign or malignant using Transfer Learning-based models. In the segmentation stage, mammograms associated with their respective ROI masks were used, allowing supervised training of the U-Net model. After mask prediction, a post-processing step was applied to remove noise, fill gaps, and visually highlight the suspicious region. In the classification stage, different approaches were tested, including an initial CNN, MobileNetV2, and EfficientNetB0. Adjusting the decision threshold for the malignant class increased the recall of this class, prioritizing the identification of malignant cases. The results showed that segmentation still presents limitations, with a validation Dice of 0.2459 and a validation IoU of 0.1453. In classification, the EfficientNetB0 model with a threshold of 0.20 achieved a recall of 0.71 for the malignant class, although with an increase in false positives. The developed application integrated segmentation, post-processing, classification, and automatic saving of results. It is concluded that the system has an academic and experimental purpose and is not suitable for clinical use, but it demonstrates the potential of CNNs in mammographic image processing.

**Keywords:** deep learning; computer vision; CBIS-DDSM; U-Net; Transfer Learning; medical image processing.

# Lista de Figuras

|    |                                                                                                                                                                |    |
|----|----------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 1  | Representação esquemática de achados mamográficos . . . . .                                                                                                    | 15 |
| 2  | Modelo básico de um neurônio artificial . . . . .                                                                                                              | 16 |
| 3  | Exemplos de funções de ativação . . . . .                                                                                                                      | 17 |
| 4  | Fluxo geral de processamento em uma Rede Neural Convolutacional . . . . .                                                                                      | 18 |
| 5  | Representação simplificada de uma tarefa de segmentação binária . . . . .                                                                                      | 18 |
| 6  | Representação simplificada da arquitetura U-Net . . . . .                                                                                                      | 19 |
| 7  | Fluxo conceitual de pós-processamento de máscaras . . . . .                                                                                                    | 20 |
| 8  | Representação simplificada do uso de Transfer Learning . . . . .                                                                                               | 20 |
| 9  | Fluxo metodológico adotado no desenvolvimento do projeto . . . . .                                                                                             | 23 |
| 10 | Evolução da função de perda durante o treinamento da U-Net . . . . .                                                                                           | 35 |
| 11 | Evolução do Dice durante o treinamento da U-Net . . . . .                                                                                                      | 35 |
| 12 | Evolução do IoU durante o treinamento da U-Net . . . . .                                                                                                       | 36 |
| 13 | Exemplo de segmentação gerada pela U-Net, contendo imagem original, máscara real e máscara prevista. . . . .                                                   | 37 |
| 14 | Exemplo de segmentação com presença de falsos positivos na máscara prevista. . . . .                                                                           | 37 |
| 15 | Evolução da acurácia durante o treinamento do classificador . . . . .                                                                                          | 40 |
| 16 | Evolução da função de perda durante o treinamento do classificador . . . . .                                                                                   | 41 |
| 17 | Evolução da AUC durante o treinamento do classificador . . . . .                                                                                               | 41 |
| 18 | Interface final da aplicação integrada, contendo segmentação, recorte da região suspeita e classificação experimental da lesão. . . . .                        | 42 |
| 19 | Exemplo de limitação da aplicação integrada, em que uma imagem maligna foi classificada como benigna devido à segmentação reduzida da região suspeita. . . . . | 43 |

# Lista de Tabelas

|    |                                                                                 |    |
|----|---------------------------------------------------------------------------------|----|
| 1  | Representação geral de uma matriz de confusão . . . . .                         | 22 |
| 2  | Organização do conjunto de dados para segmentação . . . . .                     | 26 |
| 3  | Configuração geral da arquitetura U-Net utilizada . . . . .                     | 27 |
| 4  | Organização do conjunto de dados para classificação . . . . .                   | 29 |
| 5  | Distribuição das imagens utilizadas na etapa de classificação . . . . .         | 29 |
| 6  | Resumo das configurações dos modelos avaliados na etapa de classificação . . .  | 30 |
| 7  | Dimensões de entrada utilizadas nos modelos . . . . .                           | 31 |
| 8  | Matriz de confusão do classificador baseado em MobileNetV2 . . . . .            | 38 |
| 9  | Relatório de classificação do modelo baseado em MobileNetV2 . . . . .           | 38 |
| 10 | Comparação dos limiares de decisão para a classe maligna . . . . .              | 39 |
| 11 | Matriz de confusão do classificador EfficientNetB0 com threshold 0,20 . . . . . | 39 |
| 12 | Relatório de classificação do classificador EfficientNetB0 com threshold 0,20 . | 39 |
| 13 | Ficha dos artefatos que compõem o repositório da aplicação . . . . .            | 50 |



# Lista de abreviaturas e siglas

|           |                                                                                    |
|-----------|------------------------------------------------------------------------------------|
| ABNT      | Associação Brasileira de Normas Técnicas                                           |
| AUC       | <i>Area Under the Curve</i> – Área sob a curva                                     |
| CBIS-DDSM | <i>Curated Breast Imaging Subset of Digital Database for Screening Mammography</i> |
| CLAHE     | <i>Contrast Limited Adaptive Histogram Equalization</i> – Equalização adaptativa   |
| CNN       | <i>Convolutional Neural Network</i> – Rede Neural Convolucional                    |
| DDSM      | <i>Digital Database for Screening Mammography</i> – Base digital de mamografias    |
| IA        | Inteligência Artificial                                                            |
| IoU       | <i>Intersection over Union</i> – Interseção sobre união                            |
| MLP       | <i>Multilayer Perceptron</i> – Perceptron multicamadas                             |
| RNA       | Rede Neural Artificial                                                             |
| ROI       | <i>Region of Interest</i> – Região de Interesse                                    |
| U-Net     | Arquitetura de rede neural convolucional para segmentação de imagens               |

# Sumário

|          |                                                     |           |
|----------|-----------------------------------------------------|-----------|
| <b>1</b> | <b>INTRODUÇÃO</b>                                   | <b>11</b> |
| 1.1      | Objetivos . . . . .                                 | 12        |
| 1.2      | Justificativa . . . . .                             | 12        |
| <b>2</b> | <b>REFERENCIAL TEÓRICO</b>                          | <b>14</b> |
| 2.1      | Câncer de Mama . . . . .                            | 14        |
| 2.2      | Mamografia . . . . .                                | 14        |
| 2.3      | Massas e Calcificações Mamárias . . . . .           | 15        |
| 2.4      | Redes Neurais Artificiais . . . . .                 | 16        |
| 2.5      | Perceptron Multicamadas e Backpropagation . . . . . | 17        |
| 2.6      | Redes Neurais Convolucionais . . . . .              | 17        |
| 2.7      | Segmentação de Imagens Médicas . . . . .            | 18        |
| 2.8      | Arquitetura U-Net . . . . .                         | 19        |
| 2.9      | Pós-processamento de Máscaras . . . . .             | 19        |
| 2.10     | Transfer Learning . . . . .                         | 20        |
| 2.11     | MobileNetV2 . . . . .                               | 20        |
| 2.12     | EfficientNetB0 . . . . .                            | 21        |
| 2.13     | Base de Dados CBIS-DDSM . . . . .                   | 21        |
| 2.14     | Métricas de Avaliação . . . . .                     | 22        |
| <b>3</b> | <b>METODOLOGIA</b>                                  | <b>23</b> |
| 3.1      | Caracterização da Pesquisa . . . . .                | 24        |
| 3.2      | Base de Dados Utilizada . . . . .                   | 24        |
| 3.3      | Ambiente de Desenvolvimento e Tecnologias . . . . . | 25        |
| 3.4      | Organização dos Dados para Segmentação . . . . .    | 26        |
| 3.5      | Modelo de Segmentação . . . . .                     | 27        |
| 3.6      | Pós-processamento das Máscaras . . . . .            | 28        |
| 3.7      | Organização dos Dados para Classificação . . . . .  | 28        |

|      |                                                          |    |
|------|----------------------------------------------------------|----|
| 3.8  | Modelos de Classificação . . . . .                       | 30 |
| 3.9  | Ajuste do Limiar de Classificação . . . . .              | 31 |
| 3.10 | Desenvolvimento da Aplicação . . . . .                   | 31 |
| 3.11 | Salvamento dos Resultados . . . . .                      | 32 |
| 3.12 | Métricas de Avaliação . . . . .                          | 33 |
| 3.13 | Considerações Éticas e Limitações da Aplicação . . . . . | 33 |
| 4    | RESULTADOS E DISCUSSÕES                                  | 34 |
| 4.1  | Organização da Base de Dados . . . . .                   | 34 |
| 4.2  | Resultados da Segmentação com U-Net . . . . .            | 34 |
| 4.3  | Pós-processamento da Máscara . . . . .                   | 37 |
| 4.4  | Resultados da Classificação Benigno/Maligno . . . . .    | 38 |
| 4.5  | Integração da Segmentação com a Classificação . . . . .  | 42 |
| 4.6  | Limitações Observadas . . . . .                          | 43 |
| 5    | CONCLUSÃO                                                | 45 |
|      | REFERÊNCIAS                                              | 47 |
|      | APÊNDICE A — ESTRUTURA DA APLICAÇÃO                      | 50 |
| A.1  | Organização do repositório . . . . .                     | 50 |
| A.2  | Repositório . . . . .                                    | 53 |
| A.3  | Instruções básicas de execução . . . . .                 | 53 |
| A.4  | Trechos principais do código . . . . .                   | 53 |

# 1 Introdução

O câncer de mama é uma doença de grande relevância em saúde pública, sendo a detecção precoce uma estratégia importante para ampliar as possibilidades de tratamento e melhorar o prognóstico das pacientes (Instituto Nacional de Câncer José Alencar Gomes da Silva, 2022a). Entre os métodos utilizados para investigação e rastreamento de alterações mamárias, a mamografia ocupa papel de destaque por permitir a visualização de estruturas internas da mama e de achados como massas e calcificações (Souza, 2012).

A interpretação de imagens mamográficas pode ser influenciada por fatores como densidade do tecido mamário, sobreposição de estruturas e qualidade da imagem adquirida (Souza, 2012). De acordo com Chala e Barros (Chala; Barros, 2007), os métodos de imagem são fundamentais na avaliação das mamas, pois contribuem para a identificação de alterações que podem exigir investigação complementar.

Com o avanço das técnicas computacionais, imagens mamográficas passaram a ser utilizadas em pesquisas envolvendo processamento digital de imagens, visão computacional e sistemas de apoio à análise médica (Lee *et al.*, 2017). A base CBIS-DDSM (*Curated Breast Imaging Subset of Digital Database for Screening Mammography*), utilizada neste trabalho, é uma versão curada da base DDSM (*Digital Database for Screening Mammography*) e contém imagens mamográficas, informações patológicas e anotações associadas a regiões de interesse, sendo organizada para pesquisas em detecção e diagnóstico auxiliado por computador (Lee *et al.*, 2017).

As Redes Neurais Convolucionais são arquiteturas amplamente utilizadas em tarefas de visão computacional, devido à sua capacidade de extrair automaticamente características visuais relevantes a partir de imagens (LeCun *et al.*, 1998). Em imagens médicas, a segmentação permite localizar espacialmente regiões de interesse, enquanto a classificação busca atribuir uma categoria à imagem ou à região analisada (Ronneberger; Fischer; Brox, 2015).

A arquitetura U-Net foi proposta para segmentação de imagens biomédicas e se destaca por combinar um caminho de contração, responsável pela extração de características, com um caminho de expansão, responsável pela reconstrução espacial da máscara segmentada (Ronneberger; Fischer; Brox, 2015). Além disso, técnicas de Transfer Learning permitem reutilizar conhecimentos aprendidos por modelos previamente treinados em novas tarefas, sendo úteis quando o conjunto de dados disponível é limitado (Pan; Yang, 2010).

Diante desse contexto, este trabalho investiga a construção de um pipeline computacional para segmentação e classificação experimental de lesões mamográficas, utilizando imagens da base CBIS-DDSM, a arquitetura U-Net para localização de regiões suspeitas e modelos convolucionais baseados em Transfer Learning para classificação binária entre lesões benignas e malignas.

## 1.1 Objetivos

O objetivo geral deste trabalho é desenvolver e avaliar um pipeline computacional integrado em Python para segmentação e classificação experimental de lesões mamográficas em imagens da base CBIS-DDSM.

Para alcançar esse objetivo, foram definidos os seguintes objetivos específicos:

- Organizar os dados da base CBIS-DDSM para as tarefas de segmentação e classificação de massas mamográficas.
- Implementar e avaliar a arquitetura U-Net para segmentação de regiões suspeitas em mamografias.
- Aplicar técnicas de pré-processamento e pós-processamento para padronização das imagens e refinamento das máscaras geradas.
- Estruturar conjuntos de dados para classificação binária de lesões em benignas e malignas.
- Treinar e avaliar modelos convolucionais, incluindo CNN inicial, MobileNetV2 e EfficientNetB0.
- Analisar o desempenho dos modelos por meio de métricas adequadas, como Dice, IoU, acurácia, precisão, recall, F1-score, AUC e matriz de confusão.
- Integrar as etapas de segmentação, classificação e salvamento dos resultados em uma aplicação desenvolvida em Streamlit.

## 1.2 Justificativa

O câncer de mama representa um importante problema de saúde pública. Segundo dados do INCA, foram estimados 73.610 novos casos de câncer de mama por ano no Brasil para o triênio 2023–2025 (Instituto Nacional de Câncer José Alencar Gomes da Silva, 2022b). Além disso, dados divulgados pelo Ministério da Saúde e pelo INCA apontam mais de 20 mil óbitos pela doença em 2023 (Ministério da Saúde, 2025). Esses números evidenciam a relevância do tema e reforçam a importância de estudos voltados ao apoio computacional à análise de imagens mamográficas.

A mamografia é um dos principais exames utilizados para rastreamento e investigação de alterações mamárias, porém sua interpretação pode ser influenciada por fatores como densidade do tecido mamário, qualidade da imagem, baixo contraste e sobreposição de estruturas. Essas características tornam o processamento computacional de mamografias uma área relevante para pesquisa acadêmica.

Estudos recentes têm demonstrado o potencial de modelos de aprendizado profundo em tarefas relacionadas à análise computacional de mamografias. A arquitetura Connected-UNets foi proposta para segmentação de massas mamográficas e reportou, na base CBIS-DDSM, Dice de 89,52% e IoU de 80,02%, indicando a relevância de arquiteturas baseadas em U-Net para delimitação de regiões suspeitas (Baccouche; Garcia-Zapirain; Castillo Olea *et al.*, 2021). Em outra abordagem, foi apresentado um sistema integrado para classificação de massas mamográficas utilizando um conjunto empilhado de redes residuais, obtendo acurácia de 95,13% e AUC de 0,95 para classificação patológica na base CBIS-DDSM (Baccouche; Garcia-Zapirain; Elmaghraby, 2022). Esses resultados evidenciam que a literatura recente tem explorado a integração entre segmentação e classificação como estratégia promissora para sistemas computacionais aplicados à mamografia.

Nesse contexto, técnicas baseadas em IA, especialmente CNNs, têm sido estudadas em tarefas de segmentação e classificação de imagens médicas. A segmentação permite localizar regiões suspeitas, enquanto a classificação busca diferenciar padrões associados a lesões benignas e malignas.

Assim, este trabalho se justifica pelo desenvolvimento de uma aplicação acadêmica e experimental capaz de integrar segmentação, pós-processamento, classificação e visualização dos resultados em mamografias da base CBIS-DDSM. A proposta não possui finalidade diagnóstica, mas busca contribuir para o estudo de métodos computacionais aplicados à análise de lesões mamográficas.

## 2 Referencial Teórico

Este capítulo sistematiza o referencial teórico fundamental para a fundamentação e análise deste estudo. A base conceitual organiza-se, inicialmente, em torno da contextualização clínica, abordando o câncer de mama, a mamografia e suas alterações patológicas. Na sequência, exploram-se os paradigmas computacionais, detalhando o funcionamento das Redes Neurais Artificiais e Convolucionais, com ênfase em segmentação via arquitetura U-Net e em técnicas de Transfer Learning aplicadas aos modelos MobileNetV2 e EfficientNetB0. Por fim, apresentam-se as características da base de dados CBIS-DDSM e os parâmetros métricos que balizam a avaliação do sistema proposto.

### 2.1 Câncer de Mama

O câncer de mama pode ser compreendido como uma doença caracterizada pelo crescimento desordenado de células mamárias, podendo originar tumores com potencial de invasão de tecidos adjacentes e disseminação para outras regiões do organismo (Costa, 2009; Gondim, 2013). Entre os tipos mais comuns, destaca-se o carcinoma ductal, que se origina nos ductos mamários, além do carcinoma lobular, associado aos lóbulos da mama (Gondim, 2013).

Diversos fatores podem estar associados ao risco de desenvolvimento do câncer de mama, incluindo idade, histórico familiar, fatores hormonais, menarca precoce, menopausa tardia, primeira gestação em idade mais avançada e histórico prévio da doença (Martins, 2016). Embora parte dos casos esteja relacionada a fatores hereditários, a maioria decorre de alterações adquiridas ao longo da vida, associadas a fatores biológicos, ambientais e comportamentais (Bilimoria; Morrow, 1995).

A detecção precoce é considerada uma estratégia importante para melhorar o prognóstico da doença, possibilitando tratamento em estágios iniciais e reduzindo a morbidade associada (Instituto Nacional de Câncer José Alencar Gomes da Silva, 2022a). Nesse contexto, exames de imagem, como a mamografia, são amplamente utilizados para rastreamento e investigação de alterações suspeitas na mama (Souza, 2012; Instituto Nacional de Câncer José Alencar Gomes da Silva, 2022a).

### 2.2 Mamografia

A mamografia é um exame de imagem baseado em raios X utilizado para avaliação do tecido mamário. Durante o exame, a mama é posicionada e comprimida entre placas do mamógrafo, procedimento que reduz a sobreposição dos tecidos e contribui para a visualização de alterações, como massas e calcificações (Souza, 2012).

As imagens mamográficas podem ser obtidas por meio de mamografia convencional ou digital. Na mamografia convencional, a imagem é registrada em filme, enquanto na mamografia digital a aquisição e o processamento são realizados de maneira eletrônica, permitindo ajustes e técnicas de realce de imagem (Chala; Barros, 2007). A mamografia é considerada uma ferramenta importante para o rastreamento do câncer de mama, principalmente por permitir a identificação de alterações ainda não palpáveis (Borghesan *et al.*, 2003; Instituto Nacional de Câncer José Alencar Gomes da Silva, 2022a).


No contexto computacional, imagens de mamografia podem ser utilizadas em sistemas de apoio à decisão, nos quais técnicas de processamento de imagem e aprendizado de máquina auxiliam na identificação, segmentação ou classificação de regiões suspeitas (Lee *et al.*, 2017).

## 2.3 Massas e Calcificações Mamárias

As alterações mamográficas podem se manifestar de diferentes formas, sendo massas e calcificações dois achados frequentemente analisados em exames de mamografia (Lee *et al.*, 2017). As massas mamárias correspondem a regiões com alteração de densidade, forma ou margem, podendo apresentar características associadas a lesões benignas ou malignas. Lesões benignas tendem a apresentar contornos mais regulares, enquanto lesões suspeitas ou malignas podem exibir margens irregulares, espiculadas ou mal definidas (Duarte, 2005).

As calcificações mamárias são depósitos de cálcio no tecido mamário, podendo estar associadas a processos benignos ou a achados suspeitos de malignidade (Resende *et al.*, 2008). Calcificações benignas geralmente apresentam maior tamanho e morfologia grosseira, enquanto microcalcificações suspeitas tendem a ser pequenas, agrupadas e com morfologia variável (Duarte, 2005).

Figura 1 — Representação esquemática de achados mamográficos



Fonte: Autoria própria, 2026.

A Figura 1 apresenta uma representação esquemática desses achados. A massa benigna é ilustrada com contorno mais regular, enquanto a massa suspeita apresenta



margens irregulares. As calcificações são representadas como pequenos pontos de maior densidade, que podem aparecer de forma isolada ou agrupada na imagem mamográfica.


A análise de massas e calcificações em mamografias é relevante para sistemas computacionais de apoio à interpretação de imagens médicas, pois essas alterações podem estar associadas a diferentes padrões visuais e diagnósticos patológicos (Lee *et al.*, 2017).

## 2.4 Redes Neurais Artificiais

As Redes Neurais Artificiais são modelos computacionais inspirados, de forma simplificada, no funcionamento do sistema nervoso biológico. Sua estrutura é composta por unidades de processamento chamadas neurônios artificiais, interligadas por conexões ponderadas (Haykin, 2001; Perelmuter *et al.*, 1995). Apesar dessa inspiração biológica, os neurônios artificiais são modelos matemáticos simplificados quando comparados aos neurônios presentes no cérebro humano (Haykin, 2001).

No modelo clássico de neurônio artificial, cada entrada é multiplicada por um peso sináptico, e os valores resultantes são combinados por uma soma ponderada. Em seguida, uma função de ativação é aplicada ao resultado, produzindo a saída do neurônio (Haykin, 2001).

Figura 2 — Modelo básico de um neurônio artificial



Fonte: Adaptado de (Haykin, 2001).

O modelo matemático de um neurônio artificial pode ser representado pelas Equações 1 e 2.


$$v_k = b_k + \sum_{i=1}^n w_i x_i \quad (1)$$

$$y_k = \varphi(v_k) \quad (2)$$

Em que  $x_i$  representa os sinais de entrada,  $w_i$  os pesos associados,  $b_k$  o bias,  $v_k$  a saída do combinador linear,  $\varphi$  a função de ativação e  $y_k$  a saída final do neurônio (Haykin, 2001).

As funções de ativação têm papel importante nas redes neurais, pois introduzem não linearidade ao modelo, permitindo a representação de relações mais complexas entre entradas e saídas (Haykin, 2001). A Figura 3 apresenta exemplos de funções de ativação.

Figura 3 — Exemplos de funções de ativação



Fonte: Adaptado de (Haykin, 2001).

Na Figura 3, a função degrau representa uma saída discreta, ativada apenas quando determinado limiar é atingido. A função linear por partes permite uma transição gradual em determinados intervalos. Já a função sigmoide produz valores contínuos entre 0 e 1, sendo frequentemente associada a problemas de classificação binária, nos quais a saída pode ser interpretada como uma probabilidade.

## 2.5 Perceptron Multicamadas e Backpropagation

O Perceptron Multicamadas, também conhecido como Multilayer Perceptron (MLP), é uma arquitetura de rede neural composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Haykin, 2001). A presença de camadas ocultas e funções de ativação não lineares permite que esse tipo de rede modele relações complexas entre entradas e saídas (Ambrósio, 2002).

O treinamento de redes neurais supervisionadas geralmente envolve a comparação entre a saída produzida pela rede e a saída esperada. A partir dessa comparação, calcula-se um erro, que é utilizado para ajustar os pesos da rede (Haykin, 2001). Um dos algoritmos mais utilizados para esse ajuste é o backpropagation, que realiza a propagação do erro no sentido inverso das conexões da rede, atualizando os pesos de forma a reduzir a função de perda (Affonso *et al.*, 2010; Elpídio, 2012).

O processo de treinamento ocorre em duas etapas principais. Na etapa *forward*, os dados de entrada percorrem a rede até gerar uma saída. Na etapa *backward*, o erro calculado é propagado de volta pela rede, permitindo a atualização dos pesos (Haykin, 2001).


## 2.6 Redes Neurais Convolucionais

As Redes Neurais Convolucionais, ou Convolutional Neural Networks (CNNs), são arquiteturas de aprendizado profundo especialmente adequadas ao processamento de dados com estrutura espacial, como imagens (LeCun *et al.*, 1998). Diferentemente de redes totalmente conectadas, as CNNs utilizam camadas convolucionais que aplicam filtros ou

kernels sobre a imagem, permitindo extrair características locais, como bordas, texturas e padrões visuais (LeCun *et al.*, 1998; Domingos, 2021).

Uma CNN geralmente é composta por camadas de convolução, funções de ativação, camadas de pooling e, em tarefas de classificação, camadas totalmente conectadas ou camadas densas finais (Domingos, 2021). As camadas convolucionais são responsáveis por extrair mapas de características, enquanto as camadas de pooling reduzem a dimensionalidade espacial, contribuindo para diminuir o custo computacional e tornar a rede mais robusta a pequenas variações na imagem (LeCun *et al.*, 1998). A Figura 4 apresenta uma estrutura geral de uma Rede Neural Convolucional.

Figura 4 — Fluxo geral de processamento em uma Rede Neural Convolucional



Fonte: Adaptado de (LeCun *et al.*, 1998).

As CNNs são amplamente aplicadas em tarefas de visão computacional, como classificação, detecção e segmentação de imagens, devido à sua capacidade de extrair automaticamente características relevantes a partir dos dados visuais (LeCun *et al.*, 1998).


## 2.7 Segmentação de Imagens Médicas

A segmentação de imagens consiste no processo de dividir uma imagem em regiões ou objetos de interesse. Em imagens médicas, essa técnica é utilizada para localizar estruturas anatômicas, órgãos, tecidos ou lesões, permitindo uma análise mais específica da região relevante (Ronneberger; Fischer; Brox, 2015; Gonzalez; Woods, 2018).

Diferentemente da classificação, que atribui uma classe a uma imagem inteira ou a uma região recortada, a segmentação busca identificar espacialmente os pixels pertencentes ao objeto de interesse (Ronneberger; Fischer; Brox, 2015). Em uma segmentação binária, a saída do modelo pode ser uma máscara na qual os pixels da região de interesse recebem valor 1 e os demais pixels recebem valor 0.

Em imagens médicas, a segmentação pode auxiliar na delimitação de regiões suspeitas, contribuindo para a análise quantitativa e visual de estruturas relevantes (Gonzalez; Woods, 2018; Ronneberger; Fischer; Brox, 2015). A Figura 5 ilustra, de forma simplificada, a diferença entre a imagem de entrada e a máscara gerada em uma tarefa de segmentação binária.

Figura 5 — Representação simplificada de uma tarefa de segmentação binária




Fonte: Autoria própria, 2026.

## 2.8 Arquitetura U-Net

A U-Net é uma arquitetura de rede neural convolucional proposta para tarefas de segmentação de imagens biomédicas (Ronneberger; Fischer; Brox, 2015). Sua estrutura é composta por dois caminhos principais: um caminho de contração, responsável por capturar informações contextuais da imagem, e um caminho de expansão, responsável por recuperar a resolução espacial da saída e permitir a localização da região segmentada (Ronneberger; Fischer; Brox, 2015).

O caminho de contração é formado por camadas convolucionais e operações de redução espacial, como pooling. Já o caminho de expansão utiliza operações de aumento de resolução, como convoluções transpostas, para reconstruir a máscara de saída (Ronneberger; Fischer; Brox, 2015). Uma característica importante da U-Net são as conexões de salto, que conectam camadas do caminho de contração a camadas correspondentes do caminho de expansão, preservando informações espaciais relevantes para a segmentação (Ronneberger; Fischer; Brox, 2015). A Figura 6 ilustra a organização geral da arquitetura U-Net.



Fonte: Adaptado de (Ronneberger; Fischer; Brox, 2015).

Devido à sua estrutura com caminhos de contração e expansão, a U-Net tornou-se uma arquitetura frequentemente utilizada em aplicações de segmentação biomédica, principalmente quando há necessidade de localizar regiões específicas em imagens (Ronneberger; Fischer; Brox, 2015).


## 2.9 Pós-processamento de Máscaras

Após a geração de uma máscara por um modelo de segmentação, técnicas de pós-processamento podem ser utilizadas para melhorar a interpretação visual e reduzir ruídos presentes na saída. Essas técnicas incluem operações morfológicas, remoção de pequenas regiões isoladas, preenchimento de buracos e seleção de componentes conectados (Gonzalez; Woods, 2018).

As operações morfológicas são métodos de processamento de imagens que analisam a forma dos objetos presentes em uma imagem binária. Entre as operações mais comuns estão erosão, dilatação, abertura e fechamento, que podem ser aplicadas para suavizar contornos, remover ruídos ou preencher pequenas falhas na máscara (Gonzalez; Woods,

2018). A Figura 7 apresenta um fluxo conceitual de pós-processamento de máscaras binárias, semelhante ao utilizado na etapa experimental deste trabalho.

Figura 7 — Fluxo conceitual de pós-processamento de máscaras




Fonte: Autoria própria, 2026.

## 2.10 Transfer Learning

O Transfer Learning, ou aprendizado por transferência, é uma técnica em que conhecimentos aprendidos por um modelo em uma tarefa ou domínio são reutilizados em uma nova tarefa relacionada (Pan; Yang, 2010). Essa abordagem é especialmente útil quando o conjunto de dados disponível para o problema específico é limitado, pois permite aproveitar representações previamente aprendidas em grandes bases de dados (Pan; Yang, 2010).

Em problemas de classificação de imagens, o Transfer Learning é frequentemente aplicado por meio de arquiteturas pré-treinadas, nas quais as camadas iniciais são utilizadas para extração de características gerais, enquanto as camadas finais são adaptadas à nova tarefa (Pan; Yang, 2010). Dessa forma, o modelo pode se beneficiar de padrões previamente aprendidos, como bordas, texturas e formas, reduzindo a necessidade de treinamento completo a partir do zero. A Figura 8 apresenta, de forma resumida, o uso de uma rede pré-treinada como extratora de características e a adaptação de uma nova camada de saída para uma tarefa específica.

Figura 8 — Representação simplificada do uso de Transfer Learning



Fonte: Adaptado de (Pan; Yang, 2010).

## 2.11 MobileNetV2

A MobileNetV2 é uma arquitetura de rede neural convolucional projetada para oferecer bom desempenho com menor custo computacional, sendo adequada para aplicações que exigem eficiência (Sandler *et al.*, 2018). A arquitetura utiliza blocos residuais invertidos e convoluções separáveis em profundidade, reduzindo o número de parâmetros e operações quando comparada a arquiteturas convolucionais mais pesadas (Sandler *et al.*, 2018).

As convoluções separáveis em profundidade permitem decompor a operação convolucional tradicional em etapas mais simples, diminuindo o custo computacional sem comprometer de forma significativa a capacidade de extração de características (Sandler

*et al.*, 2018). Por essa razão, arquiteturas como a MobileNetV2 são frequentemente utilizadas em cenários nos quais há restrições de processamento ou necessidade de modelos mais leves.

## 2.12 EfficientNetB0

A EfficientNetB0 é uma arquitetura de Rede Neural Convolutacional baseada em uma estratégia de escalonamento composto (Tan; Le, 2019). Diferentemente de abordagens que aumentam apenas a profundidade, a largura ou a resolução da rede, a EfficientNet busca equilibrar esses três fatores de maneira sistemática.

A versão EfficientNetB0 corresponde ao modelo base da família EfficientNet e foi projetada para apresentar bom desempenho com número reduzido de parâmetros em comparação a arquiteturas convolucionais mais profundas. Por esse motivo, pode ser utilizada em tarefas de classificação de imagens por meio de Transfer Learning, aproveitando características previamente aprendidas em grandes bases de dados.

Neste trabalho, a EfficientNetB0 foi utilizada como extratora de características para a classificação experimental de lesões mamográficas em benignas ou malignas, substituindo sua camada final original por uma nova saída binária com ativação sigmoide.

## 2.13 Base de Dados CBIS-DDSM

A base CBIS-DDSM, sigla para Curated Breast Imaging Subset of DDSM, é uma versão curada da base Digital Database for Screening Mammography, organizada para apoiar pesquisas em sistemas de diagnóstico auxiliado por computador em mamografia (Lee *et al.*, 2017). A base contém casos de massas e calcificações, imagens mamográficas, informações patológicas, segmentações e caixas delimitadoras associadas às lesões (Lee *et al.*, 2017).

Segundo Lee *et al.* (2017), a CBIS-DDSM inclui casos de calcificações e massas mamográficas, com diagnósticos patológicos e dados organizados de forma semelhante a conjuntos modernos utilizados em visão computacional. Essas características tornam a base adequada para tarefas como classificação, detecção e segmentação de lesões mamográficas.

Por reunir imagens mamográficas e anotações associadas às regiões de interesse, a CBIS-DDSM é frequentemente utilizada em pesquisas que envolvem aprendizado de máquina, visão computacional e sistemas de apoio à análise de exames de mama (Lee *et al.*, 2017).

## 2.14 Métricas de Avaliação

A avaliação de modelos de aprendizado de máquina depende da tarefa realizada. Em problemas de segmentação, métricas baseadas na sobreposição entre a máscara prevista e a máscara real são amplamente utilizadas. Entre essas métricas, destacam-se o Dice Coefficient e a Intersection over Union (IoU) (Dice, 1945; Jaccard, 1912).

O Dice Coefficient mede a similaridade entre duas regiões, considerando a sobreposição entre elas (Dice, 1945). A métrica IoU, também conhecida como índice de Jaccard, mede a razão entre a interseção e a união das regiões segmentadas (Jaccard, 1912). Em tarefas de segmentação, essas métricas são mais informativas que a acurácia quando a região de interesse ocupa uma pequena parte da imagem.

Em problemas de classificação, métricas como acurácia, precisão, recall, F1-score, AUC e matriz de confusão são frequentemente empregadas (Fawcett, 2006). A acurácia representa a proporção total de classificações corretas. A precisão indica, entre as amostras classificadas como positivas, quantas foram corretamente classificadas. O recall mede a capacidade do modelo de identificar corretamente os casos positivos. O F1-score corresponde à média harmônica entre precisão e recall (Fawcett, 2006).

A AUC, associada à curva ROC, avalia a capacidade do classificador de distinguir entre as classes em diferentes limiares de decisão (Fawcett, 2006). Já a matriz de confusão permite analisar a distribuição de acertos e erros do modelo, incluindo verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos.

Tabela 1 — Representação geral de uma matriz de confusão

| Classe real / Classe prevista | Positiva                 | Negativa                 |
|-------------------------------|--------------------------|--------------------------|
| Positiva                      | Verdadeiro Positivo (VP) | Falso Negativo (FN)      |
| Negativa                      | Falso Positivo (FP)      | Verdadeiro Negativo (VN) |

Fonte: Autoria própria, 2026.


Na matriz de confusão, os resultados são organizados de acordo com a classe real e a classe prevista pelo modelo. Considerando uma classe positiva, o verdadeiro positivo (VP) representa uma amostra positiva classificada corretamente como positiva. O verdadeiro negativo (VN) representa uma amostra negativa classificada corretamente como negativa. O falso positivo (FP) ocorre quando uma amostra negativa é classificada incorretamente como positiva, enquanto o falso negativo (FN) ocorre quando uma amostra positiva é classificada incorretamente como negativa. No contexto deste trabalho, a classe maligna foi considerada como classe positiva na análise dos classificadores.

### 3 Metodologia

Este capítulo detalha os procedimentos experimentais e as escolhas técnicas que viabilizaram a construção do sistema proposto. Para cumprir o objetivo de desenvolver uma aplicação integrada de apoio ao estudo de mamografias, a metodologia estrutura-se em um fluxo de processamento que percorre desde o tratamento de dados da base CBIS-DDSM até a avaliação de desempenho dos modelos.

O percurso metodológico aqui descrito sistematiza o treinamento da arquitetura U-Net para a localização de regiões suspeitas e o emprego de Transfer Learning para a classificação binária de lesões, culminando na descrição da interface em Python desenvolvida para consolidar essas etapas em um ambiente funcional e acadêmico. A Figura 9 apresenta o fluxo geral da metodologia adotada.

Figura 9 — Fluxo metodológico adotado no desenvolvimento do projeto



Fonte: Autoria própria, 2026.



## 3.1 Caracterização da Pesquisa

A pesquisa desenvolvida possui caráter aplicado e experimental, pois busca construir e avaliar uma solução computacional voltada à análise de imagens mamográficas. O estudo também apresenta abordagem quantitativa, uma vez que os modelos foram avaliados por meio de métricas numéricas, como Dice Coefficient, IoU, acurácia, precisão, recall, F1-score, AUC e matriz de confusão.

O desenvolvimento foi dividido em duas tarefas principais. A primeira corresponde à segmentação de regiões suspeitas em mamografias, utilizando uma arquitetura U-Net. A segunda corresponde à classificação experimental das lesões em benignas ou malignas, utilizando modelos convolucionais baseados em Transfer Learning.

## 3.2 Base de Dados Utilizada

A base de dados utilizada neste trabalho foi a CBIS-DDSM (*Curated Breast Imaging Subset of Digital Database for Screening Mammography*), uma versão curada e organizada da base DDSM (*Digital Database for Screening Mammography*), desenvolvida para apoiar pesquisas em diagnóstico auxiliado por computador aplicado à mamografia (Lee *et al.*, 2017). Essa base reúne exames mamográficos associados a informações clínicas e patológicas, além de anotações referentes às regiões de interesse das lesões.

Para o desenvolvimento deste trabalho, foi utilizada uma versão da CBIS-DDSM disponibilizada no Kaggle, contendo imagens em formato JPG e arquivos CSV com informações estruturadas sobre os casos. Embora a base CBIS-DDSM contenha casos relacionados a massas e calcificações mamárias, a implementação desenvolvida concentrou-se nos casos de massas mamográficas, por apresentarem maior compatibilidade com o fluxo proposto de segmentação e classificação experimental.

Na versão utilizada, foram considerados os registros associados aos arquivos de massas mamográficas. O arquivo *mass\_case\_description\_train\_set.csv* contém 1.318 registros e o arquivo *mass\_case\_description\_test\_set.csv* contém 378 registros, totalizando 1.696 registros relacionados a massas mamográficas. Esses registros incluem informações como identificação do paciente, lateralidade da mama, tipo de anormalidade, diagnóstico patológico, caminhos das imagens, imagens recortadas das lesões e máscaras das regiões de interesse.

Os principais arquivos utilizados neste trabalho foram:

- *mass\_case\_description\_train\_set.csv*: arquivo contendo os registros de massas mamográficas do conjunto de treinamento;
- *mass\_case\_description\_test\_set.csv*: arquivo contendo os registros de massas mamográficas do conjunto de validação/teste;

- *dicom\_info.csv*: arquivo utilizado para relacionar os caminhos informados nos arquivos CSV com as imagens JPG disponíveis na versão da base utilizada.

O arquivo *dicom\_info.csv* foi necessário porque os caminhos indicados nos arquivos de descrição dos casos não apontavam diretamente para os arquivos JPG utilizados no projeto. Dessa forma, esse arquivo foi empregado para localizar corretamente as mamografias completas, as imagens recortadas das lesões e as máscaras ROI correspondentes.

A organização dos dados foi realizada considerando duas tarefas distintas: segmentação e classificação. Embora ambas tenham sido construídas a partir dos mesmos registros de massas mamográficas da base CBIS-DDSM, os dados utilizados em cada etapa possuem finalidades diferentes. Na segmentação, foram utilizadas mamografias completas associadas às respectivas máscaras ROI. Na classificação, foram utilizadas imagens recortadas das lesões, organizadas de acordo com o rótulo patológico de cada caso.

Dessa forma, não se trata de uma duplicação simples das mesmas imagens, mas da utilização de diferentes representações do mesmo conjunto de casos. A mamografia completa foi utilizada para preservar o contexto espacial necessário à segmentação, enquanto o recorte da lesão foi utilizado para concentrar a análise do classificador na região suspeita.

### 3.3 Ambiente de Desenvolvimento e Tecnologias

O projeto foi desenvolvido na linguagem Python, utilizando o ambiente Visual Studio Code. Para isolar as dependências do projeto, foi utilizado um ambiente virtual. As principais bibliotecas utilizadas foram:

- **NumPy**: utilizada para manipulação de matrizes e operações numéricas;
- **Pandas**: utilizada para leitura e manipulação dos arquivos CSV da base de dados;
- **OpenCV**: utilizada para leitura, redimensionamento, binarização, realce e pós-processamento das imagens;
- **TensorFlow/Keras**: utilizada para construção, treinamento e carregamento dos modelos de redes neurais;
- **Matplotlib**: utilizada para geração dos gráficos de treinamento;
- **Scikit-learn**: utilizada para cálculo de métricas de classificação e matriz de confusão;
- **Streamlit**: utilizada para criação da interface gráfica da aplicação.

A estrutura principal do projeto foi organizada em arquivos Python separados, com funções específicas para pré-processamento, treinamento da U-Net, treinamento do classificador, métricas, pós-processamento e aplicação final.

### 3.4 Organização dos Dados para Segmentação

Para a tarefa de segmentação, foi criada uma estrutura de diretórios específica para armazenar separadamente as imagens mamográficas completas e suas respectivas máscaras ROI, divididas em conjuntos de treinamento e validação. Nessa etapa, cada amostra foi formada por uma mamografia completa como entrada e uma máscara binária correspondente como saída esperada. Essa organização preserva o alinhamento espacial entre imagem e máscara, condição necessária para o treinamento supervisionado da U-Net.

A organização dos dados para segmentação seguiu a separação dos arquivos de massas mamográficas da base CBIS-DDSM. O conjunto de treinamento foi composto por registros provenientes do arquivo *mass\_case\_description\_train\_set.csv*, enquanto o conjunto de validação/teste foi composto por registros provenientes do arquivo *mass\_case\_description\_test\_set.csv*. A estrutura de diretórios adotada é apresentada na Tabela 2.

Tabela 2 — Organização do conjunto de dados para segmentação

| Diretório                 | Finalidade                                                                     |
|---------------------------|--------------------------------------------------------------------------------|
| dataset_seg/images/train/ | Armazena as imagens mamográficas completas utilizadas no treinamento da U-Net. |
| dataset_seg/images/val/   | Armazena as imagens mamográficas completas utilizadas na validação da U-Net.   |
| dataset_seg/masks/train/  | Armazena as máscaras ROI correspondentes às imagens de treinamento.            |
| dataset_seg/masks/val/    | Armazena as máscaras ROI correspondentes às imagens de validação.              |

Fonte: Autoria própria, 2026.

Inicialmente, foi testado o uso das imagens recortadas das lesões em conjunto com as máscaras ROI. No entanto, durante os primeiros treinamentos, observou-se que essa relação gerava desalinhamento entre a imagem de entrada e a máscara esperada. Como consequência, o modelo apresentava valores de Dice Coefficient e IoU próximos de zero e produzia máscaras praticamente vazias.

Após essa verificação, a organização foi corrigida utilizando a mamografia completa associada à respectiva máscara ROI. Essa alteração permitiu maior coerência espacial entre a imagem de entrada e a máscara utilizada como saída esperada no treinamento da U-Net, possibilitando que o modelo aprendesse a localizar a região suspeita no contexto da imagem mamográfica.

Antes do treinamento, as imagens e máscaras foram redimensionadas para  $256 \times 256$  pixels. As imagens foram convertidas para escala de cinza e normalizadas para o intervalo entre 0 e 1. As máscaras foram convertidas para imagens binárias, nas quais os pixels pertencentes à região de interesse assumem valor 1 e os demais pixels assumem valor 0. Dessa forma, cada amostra de treinamento foi composta por uma imagem mamográfica normalizada e uma máscara binária correspondente.

### 3.5 Modelo de Segmentação

Para a etapa de segmentação foi utilizada uma arquitetura U-Net, modelo amplamente empregado em tarefas de segmentação de imagens biomédicas (Ronneberger; Fischer; Brox, 2015). A rede foi treinada para receber como entrada uma imagem mamográfica em escala de cinza, com dimensão de  $256 \times 256 \times 1$ , e gerar como saída uma máscara binária de mesma resolução indicando a região suspeita.

A arquitetura utilizada seguiu a estrutura geral da U-Net, composta por um caminho de contração e um caminho de expansão. O caminho de contração foi responsável pela extração de características da imagem, enquanto o caminho de expansão foi responsável pela reconstrução espacial da máscara de saída. As conexões de salto foram utilizadas para combinar informações espaciais de camadas iniciais com informações semânticas de camadas mais profundas.

Na implementação adotada, o caminho de contração foi organizado em blocos convolucionais com 64, 128, 256 e 512 filtros, seguidos por uma camada central com 1024 filtros. No caminho de expansão, a quantidade de filtros foi reduzida progressivamente, seguindo a sequência 512, 256, 128 e 64 filtros. A camada de saída utilizou uma convolução  $1 \times 1$  com um único filtro e função de ativação sigmoide, responsável por gerar a máscara binária da região suspeita.

Tabela 3 — Configuração geral da arquitetura U-Net utilizada

| <b>Etapas</b>  | <b>Filtros</b>            | <b>Função</b>                              |
|----------------|---------------------------|--------------------------------------------|
| Entrada        | $256 \times 256 \times 1$ | Imagem mamográfica em escala de cinza      |
| Contração 1    | 64                        | Extração inicial de características        |
| Contração 2    | 128                       | Extração de padrões intermediários         |
| Contração 3    | 256                       | Extração de características mais profundas |
| Contração 4    | 512                       | Representação semântica da imagem          |
| Camada central | 1024                      | Maior nível de abstração                   |
| Expansão 1     | 512                       | Reconstrução espacial da máscara           |
| Expansão 2     | 256                       | Recuperação de detalhes espaciais          |
| Expansão 3     | 128                       | Refinamento da segmentação                 |
| Expansão 4     | 64                        | Geração final da máscara                   |
| Saída          | 1                         | Máscara binária com ativação sigmoide      |

Fonte: Autoria própria, 2026.

O treinamento foi realizado utilizando uma função de perda combinada, composta pela soma da Binary Crossentropy com a Dice Loss. Essa combinação foi adotada devido ao desbalanceamento entre fundo e região de interesse, comum em problemas de segmentação médica, nos quais a área lesionada ocupa uma pequena parte da imagem.

Durante o treinamento, foram monitoradas as seguintes métricas:

- Dice Coefficient;
- IoU;
- Loss de treinamento;
- Loss de validação.

Também foram utilizados mecanismos de controle de treinamento, como *Early Stopping*, para interromper o treinamento quando não houvesse melhora significativa, e redução da taxa de aprendizado quando a perda de validação deixasse de melhorar.

## 3.6 Pós-processamento das Máscaras

Após a predição da U-Net, a máscara gerada passou por uma etapa de pós-processamento. Essa etapa teve como objetivo reduzir ruídos, remover pequenas regiões isoladas e tornar a saída mais interpretável visualmente.

O pós-processamento incluiu as seguintes operações:

- binarização da máscara prevista a partir de um limiar definido;
- remoção de pequenas regiões desconectadas;
- manutenção da maior componente conectada;
- preenchimento de buracos internos;
- suavização da máscara por operações morfológicas;
- geração de uma imagem com a região segmentada destacada sobre a mamografia original.

A imagem resultante foi utilizada na aplicação para permitir a visualização da região suspeita destacada. Além disso, a área segmentada foi calculada em pixels e em percentual aproximado em relação à imagem total.

## 3.7 Organização dos Dados para Classificação

Para a etapa de classificação, as imagens foram organizadas em duas classes: benigna e maligna. A definição das classes foi realizada a partir da coluna *pathology* dos arquivos CSV da base CBIS-DDSM. Os casos identificados como *MALIGNANT*

foram classificados como malignos, enquanto os casos identificados como *BENIGN* e *BENIGN\_WITHOUT\_CALLBACK* foram agrupados na classe benigna.

Diferentemente da etapa de segmentação, em que foram utilizadas mamografias completas associadas às máscaras ROI, na etapa de classificação foram utilizadas imagens recortadas das lesões. Essa escolha foi adotada porque os recortes concentram a região de interesse, reduzindo a influência de áreas externas à lesão e tornando os dados mais adequados para a diferenciação experimental entre padrões benignos e malignos.

A divisão dos dados seguiu a separação entre treinamento e validação/teste dos registros de massas mamográficas da base CBIS-DDSM. Assim, os conjuntos de classificação foram derivados dos mesmos casos utilizados no projeto, porém com outra representação de entrada: recortes das lesões em vez de mamografias completas. O conjunto de treinamento foi composto por 1.318 imagens recortadas de lesões, sendo 681 benignas e 637 malignas. O conjunto de validação/teste foi composto por 378 imagens recortadas, sendo 231 benignas e 147 malignas. Assim, foram utilizadas 1.696 imagens recortadas na etapa de classificação, distribuídas em 912 imagens benignas e 784 imagens malignas.

A estrutura de diretórios utilizada para o treinamento e validação do classificador é apresentada na Tabela 4.

Tabela 4 — Organização do conjunto de dados para classificação

| Diretório                            | Finalidade                                                                      |
|--------------------------------------|---------------------------------------------------------------------------------|
| dataset_classificacao/train/benigno/ | Armazena imagens de lesões benignas utilizadas no treinamento do classificador. |
| dataset_classificacao/train/maligno/ | Armazena imagens de lesões malignas utilizadas no treinamento do classificador. |
| dataset_classificacao/val/benigno/   | Armazena imagens de lesões benignas utilizadas na validação do classificador.   |
| dataset_classificacao/val/maligno/   | Armazena imagens de lesões malignas utilizadas na validação do classificador.   |

Fonte: Autoria própria, 2026.

Para explicitar a distribuição das imagens utilizadas, a Tabela 5 apresenta a quantidade de amostras por classe em cada conjunto.

Tabela 5 — Distribuição das imagens utilizadas na etapa de classificação

| Conjunto        | Benigno | Maligno | Total |
|-----------------|---------|---------|-------|
| Treinamento     | 681     | 637     | 1318  |
| Validação/Teste | 231     | 147     | 378   |
| Total           | 912     | 784     | 1696  |

Fonte: Autoria própria, 2026.

Antes do treinamento, as imagens foram redimensionadas para o tamanho de entrada exigido pelos modelos convolucionais utilizados. Também foi aplicado realce de contraste com CLAHE (*Contrast Limited Adaptive Histogram Equalization*) em uma das tentativas de melhoria do classificador, com o objetivo de destacar padrões de textura e densidade nas regiões analisadas.

### 3.8 Modelos de Classificação

A etapa de classificação foi desenvolvida por meio de três abordagens principais: uma CNN inicial treinada sem pesos pré-treinados, um modelo baseado em MobileNetV2 e um modelo baseado em EfficientNetB0.

A CNN inicial foi utilizada como modelo de referência, permitindo avaliar o comportamento de uma arquitetura convolucional mais simples na tarefa de classificação binária. Essa rede foi composta por blocos convolucionais, camadas de *pooling*, camada densa intermediária, regularização por *dropout* e uma camada final com ativação sigmoide.

Em seguida, foram utilizadas arquiteturas baseadas em Transfer Learning. A MobileNetV2 e a EfficientNetB0 foram empregadas como bases convolucionais pré-treinadas, com remoção da camada original de classificação e adaptação de uma nova cabeça de classificação binária. Essa adaptação foi necessária porque os modelos originais foram treinados para tarefas multiclasse, enquanto este trabalho considera apenas duas classes: benigna e maligna.

Na tentativa com EfficientNetB0, também foram avaliadas estratégias adicionais, como aumento de dados, ponderação das classes, realce de contraste com CLAHE, ajuste do limiar de decisão e *fine-tuning* das últimas camadas do modelo. A saída dos classificadores foi configurada com uma função sigmoide, de modo que o modelo retornasse uma probabilidade estimada para a classe maligna.

A Tabela 6 apresenta um resumo das configurações gerais dos modelos avaliados na etapa de classificação.

Tabela 6 — Resumo das configurações dos modelos avaliados na etapa de classificação

| Modelo         | Configuração geral                                                                                                                                                                                                                              |
|----------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| CNN inicial    | Modelo treinado sem pesos pré-treinados, composto por blocos convolucionais, camadas de <i>pooling</i> , camada densa intermediária, <i>dropout</i> e saída binária com ativação sigmoide.                                                      |
| MobileNetV2    | Modelo baseado em Transfer Learning, com base convolucional pré-treinada, remoção da camada original de classificação e adição de uma nova cabeça de classificação binária com saída sigmoide.                                                  |
| EfficientNetB0 | Modelo baseado em Transfer Learning, com base convolucional pré-treinada, nova cabeça de classificação binária, aumento de dados, ponderação de classes, teste com CLAHE, ajuste do limiar de decisão e <i>fine-tuning</i> das últimas camadas. |

Fonte: Autoria própria, 2026.

As dimensões de entrada utilizadas em cada modelo são apresentadas na Tabela 7. Essa informação é relevante porque a segmentação e a classificação utilizaram representações distintas das imagens: a U-Net recebeu mamografias em escala de cinza, enquanto os classificadores receberam recortes das lesões em três canais.

Tabela 7 — Dimensões de entrada utilizadas nos modelos

| <b>Etapa</b>  | <b>Modelo</b>  | <b>Dimensão de entrada</b> |
|---------------|----------------|----------------------------|
| Segmentação   | U-Net          | $256 \times 256 \times 1$  |
| Classificação | CNN inicial    | $224 \times 224 \times 3$  |
| Classificação | MobileNetV2    | $224 \times 224 \times 3$  |
| Classificação | EfficientNetB0 | $224 \times 224 \times 3$  |

Fonte: Autoria própria, 2026.

### 3.9 Ajuste do Limiar de Classificação

Após o treinamento dos classificadores, foram avaliados diferentes valores de limiar para a decisão entre benigno e maligno. Essa etapa foi realizada porque o limiar padrão de 0,50 nem sempre oferece o melhor equilíbrio entre precisão e recall, principalmente em problemas nos quais falsos negativos são especialmente relevantes.

Para cada limiar avaliado, foram calculadas a acurácia geral, a precisão da classe maligna, o recall da classe maligna e o F1-score da classe maligna. A seleção do limiar adotado na aplicação integrada foi realizada com base no comportamento dessas métricas, priorizando a identificação de casos malignos no contexto experimental do trabalho.

Os resultados comparativos dos limiares de decisão são apresentados no Capítulo 4, juntamente com as matrizes de confusão e os relatórios de classificação dos modelos avaliados.

### 3.10 Desenvolvimento da Aplicação

A aplicação foi desenvolvida utilizando a biblioteca Streamlit. A interface permite que o usuário envie uma imagem de mamografia em formato JPG ou PNG. Após o envio, a imagem é pré-processada e enviada ao modelo U-Net para geração da máscara de segmentação.

O fluxo da aplicação ocorre da seguinte forma:

1. envio da imagem mamográfica pelo usuário;
2. redimensionamento e normalização da imagem;
3. aplicação do modelo U-Net;
4. geração da máscara bruta;
5. pós-processamento da máscara;
6. destaque visual da região suspeita;
7. recorte da região segmentada;



8. classificação experimental da lesão;
9. exibição dos resultados na interface;
10. salvamento automático dos arquivos gerados.

A aplicação exibe quatro resultados principais: imagem original, máscara bruta da U-Net, máscara pós-processada e imagem com a região suspeita destacada. Quando há região segmentada válida, também é exibido o recorte utilizado para classificação e o resultado experimental como benigno ou maligno.

Além disso, a aplicação informa a quantidade de pixels segmentados, o percentual aproximado da área segmentada e a qualidade da segmentação. Quando a área segmentada é muito pequena, a interface apresenta um alerta indicando que a classificação pode não ser confiável.

### 3.11 Salvamento dos Resultados

A aplicação foi configurada para salvar automaticamente os resultados gerados a cada execução. Para cada imagem analisada, é criada uma pasta dentro do diretório *resultados\_tcc*. Nessa pasta são armazenados:

- imagem original;
- máscara bruta gerada pela U-Net;
- máscara pós-processada;
- imagem com a região suspeita destacada;
- recorte utilizado para classificação;
- arquivo de informações da execução.

O arquivo de informações contém dados como nome da imagem analisada, limiar utilizado na segmentação, quantidade de pixels segmentados, percentual da área segmentada, qualidade da segmentação, classe prevista pelo classificador e probabilidade estimada para a classe maligna.

Essa organização permitiu documentar os testes realizados e selecionar imagens representativas para a seção de Resultados e Discussões.

## 3.12 Métricas de Avaliação

Para avaliar a etapa de segmentação, foram utilizadas as métricas Dice Coefficient e IoU. Essas métricas avaliam a sobreposição entre a máscara prevista pelo modelo e a máscara real. A acurácia não foi considerada a principal métrica da segmentação, pois a região de interesse ocupa uma pequena área em relação ao fundo da imagem, o que pode tornar essa métrica pouco informativa.

Para avaliar a etapa de classificação, foram utilizadas as seguintes métricas:

- acurácia;
- precisão;
- recall;
- F1-score;
- AUC;
- matriz de confusão.

A análise da matriz de confusão foi utilizada para verificar a quantidade de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos. Em especial, foi dada atenção ao recall da classe maligna, devido à importância de reduzir casos malignos classificados incorretamente como benignos.

## 3.13 Considerações Éticas e Limitações da Aplicação

A aplicação desenvolvida possui finalidade exclusivamente acadêmica e experimental. Os resultados gerados não devem ser interpretados como diagnóstico médico nem utilizados para tomada de decisão clínica. A análise de mamografias deve ser realizada por profissionais da área da saúde, considerando protocolos clínicos, histórico da paciente e avaliação especializada.

Além disso, os modelos desenvolvidos apresentam limitações relacionadas à qualidade das imagens, à organização da base de dados, ao comportamento dos modelos diante das classes, ao tamanho do conjunto de treinamento e à dependência entre segmentação e classificação. Em especial, a classificação integrada depende da qualidade da segmentação: quando a U-Net identifica uma região incorreta ou muito pequena, o recorte enviado ao classificador pode não representar adequadamente a lesão.

## 4 Resultados e discussões

Este capítulo sistematiza e analisa as evidências empíricas resultantes da aplicação do fluxo metodológico proposto sobre a base de dados CBIS-DDSM. Os achados são apresentados em eixos que acompanham a evolução do processamento: partindo da validação da segmentação via arquitetura U-Net até a avaliação do desempenho preditivo dos modelos de classificação baseados em Transfer Learning.

Mais do que descrever a funcionalidade da ferramenta, esta seção discute o comportamento das métricas e a eficácia do pipeline integrado, que consolida etapas de predição, pós-processamento de máscaras e classificação experimental. A análise fundamenta-se na documentação sistemática dos resultados, incluindo o processamento de imagens e o salvamento automático de metadados, permitindo uma avaliação crítica das potencialidades e limitações da solução computacional desenvolvida.

### 4.1 Organização da Base de Dados

A organização da base CBIS-DDSM foi uma etapa determinante para os resultados obtidos. Na etapa de segmentação, verificou-se inicialmente que o uso das imagens recortadas das lesões em conjunto com as máscaras ROI gerava desalinhamento espacial entre entrada e saída esperada. Como consequência, a U-Net produzia máscaras praticamente vazias e as métricas Dice Coefficient e IoU permaneciam próximas de zero.

Após essa constatação, os dados foram reorganizados utilizando as mamografias completas associadas às respectivas máscaras ROI. Essa correção tornou o pareamento imagem-máscara mais coerente para o treinamento supervisionado da U-Net e permitiu que o modelo passasse a localizar regiões suspeitas nas mamografias.


Para a classificação, foram mantidas as imagens recortadas das lesões, organizadas segundo a coluna *pathology*. Os casos classificados como *MALIGNANT* foram associados à classe maligna, enquanto os casos *BENIGN* e *BENIGN\_WITHOUT\_CALLBACK* foram agrupados na classe benigna. Dessa forma, a segmentação utilizou mamografias completas e máscaras ROI, enquanto a classificação utilizou recortes das lesões e rótulos patológicos.

### 4.2 Resultados da Segmentação com U-Net

Após a correção no pareamento entre imagens e máscaras, a U-Net passou a identificar regiões suspeitas nas mamografias. O melhor resultado da U-Net foi obtido na época 17, com Dice de validação igual a 0,2459, IoU de validação igual a 0,1453 e loss de validação igual a 0,8262.


As Figuras 10, 11 e 12 apresentam, respectivamente, a evolução da função de perda, do Dice e do IoU durante o treinamento da U-Net.

Figura 10 — Evolução da função de perda durante o treinamento da U-Net




Fonte: Autoria própria, 2026.

Figura 11 — Evolução do Dice durante o treinamento da U-Net



Fonte: Autoria própria, 2026.

Figura 12 — Evolução do IoU durante o treinamento da U-Net




Fonte: Autoria própria, 2026.

A Figura 10 mostra que a função de perda da U-Net apresentou tendência geral de redução ao longo das épocas, indicando aprendizado progressivo durante o treinamento. A Figura 11 mostra que o Dice permaneceu próximo de zero nas primeiras épocas e passou a aumentar posteriormente, evidenciando que o modelo deixou de prever predominantemente o fundo da imagem e começou a identificar regiões associadas à lesão. De forma semelhante, a Figura 12 apresenta aumento gradual da IoU, embora com oscilações na validação. Essas oscilações são compatíveis com a dificuldade da tarefa, pois as regiões suspeitas são pequenas, apresentam baixo contraste e podem variar significativamente em forma e textura.

Apesar de os valores de Dice e IoU ainda serem considerados baixos, os resultados indicam que o modelo deixou de prever apenas o fundo da imagem e passou a localizar regiões associadas às áreas suspeitas. A acurácia, embora alta em algumas épocas, não foi considerada a métrica principal para avaliação da segmentação, pois a maior parte da imagem corresponde ao fundo. Assim, métricas como Dice Coefficient e IoU foram mais adequadas para avaliar a sobreposição entre a máscara prevista e a máscara real.

A análise visual mostrou que, em alguns casos, a U-Net conseguiu produzir máscaras próximas às regiões de interesse. Em outros, foram observados falsos positivos, regiões deslocadas ou segmentações muito pequenas, evidenciando a complexidade da tarefa.

Figura 13 — Exemplo de segmentação gerada pela U-Net, contendo imagem original, máscara real e máscara prevista.



Fonte: Autoria própria, 2026.

Figura 14 — Exemplo de segmentação com presença de falsos positivos na máscara prevista.



Fonte: Autoria própria, 2026.

A Figura 13 apresenta um caso em que a máscara prevista pela U-Net se aproxima da região de interesse indicada pela máscara real, embora ainda apresente diferença em relação ao tamanho e ao contorno da lesão. Esse resultado indica que o modelo conseguiu localizar parcialmente a região suspeita.

A Figura 14, por outro lado, evidencia uma limitação da segmentação, com a presença de regiões previstas fora da área principal da lesão. Esses falsos positivos mostram que, embora a U-Net tenha aprendido padrões associados às regiões suspeitas, ainda há dificuldade em delimitar a lesão de forma precisa em todos os casos.

### 4.3 Pós-processamento da Máscara

Para melhorar a interpretação visual dos resultados, foi implementada uma etapa de pós-processamento da máscara prevista pela U-Net. Essa etapa incluiu a binarização da saída do modelo, a remoção de pequenos ruídos, a manutenção da maior região segmentada, o preenchimento de buracos internos e a criação de uma sobreposição visual da região suspeita sobre a mamografia original.

Em um dos testes realizados, a aplicação segmentou 1484 pixels, correspondendo a aproximadamente 2,2644% da imagem analisada. Visualmente, a região destacada ficou

próxima à área de maior densidade presente na mamografia. Esse resultado demonstra que o pós-processamento contribuiu para tornar a saída do modelo mais clara e interpretável.

## 4.4 Resultados da Classificação Benigno/Maligno

Além da segmentação, foi implementada uma etapa de classificação experimental das lesões em benignas e malignas. Para essa tarefa, foram utilizadas as imagens recortadas das lesões e a coluna *pathology* dos arquivos CSV da base CBIS-DDSM. Os casos classificados como *MALIGNANT* foram organizados na classe maligna, enquanto os casos *BENIGN* e *BENIGN\_WITHOUT\_CALLBACK* foram organizados na classe benigna.

Inicialmente, foi avaliada uma CNN inicial treinada sem pesos pré-treinados. No entanto, o modelo apresentou comportamento enviesado para a classe benigna. A matriz de confusão indicou que todos os casos da validação foram classificados como benignos, resultando em recall igual a zero para a classe maligna. Embora a acurácia tenha sido de aproximadamente 65%, esse valor não representava um bom desempenho, pois o modelo não conseguia identificar casos malignos.

Para corrigir essa limitação, foi adotada uma abordagem utilizando Transfer Learning com a arquitetura MobileNetV2, aumento de dados e ponderação das classes. Essa estratégia apresentou melhora significativa, permitindo que o modelo passasse a reconhecer amostras das duas classes. Com essa abordagem, o classificador obteve acurácia aproximada de 67%, AUC de aproximadamente 0,71 e F1-score de 0,57 para a classe maligna.

A matriz de confusão obtida com o modelo baseado em MobileNetV2 é apresentada na Tabela 8.

Tabela 8 — Matriz de confusão do classificador baseado em MobileNetV2

|              | Previsto Benigno | Previsto Maligno |
|--------------|------------------|------------------|
| Real Benigno | 169              | 62               |
| Real Maligno | 64               | 83               |

Fonte: Autoria própria, 2026.

O relatório de classificação do modelo baseado em MobileNetV2 é apresentado na Tabela 9.

Tabela 9 — Relatório de classificação do modelo baseado em MobileNetV2

| Classe                 | Precisão | Recall | F1-score | Suporte |
|------------------------|----------|--------|----------|---------|
| Benigno                | 0,73     | 0,73   | 0,73     | 231     |
| Maligno                | 0,57     | 0,56   | 0,57     | 147     |
| <b>Acurácia</b>        | 0,67     |        |          | 378     |
| <b>Média macro</b>     | 0,65     | 0,65   | 0,65     | 378     |
| <b>Média ponderada</b> | 0,67     | 0,67   | 0,67     | 378     |

Fonte: Autoria própria, 2026.

Apesar da melhora em relação à CNN inicial, ainda foram observados falsos negativos relevantes, isto é, casos malignos classificados como benignos. Como esse tipo de erro é crítico em aplicações relacionadas ao câncer de mama, foi realizada uma nova tentativa utilizando a arquitetura EfficientNetB0, também baseada em Transfer Learning. Nessa nova etapa, foi aplicado realce de contraste com CLAHE nas imagens, aumento de dados, ponderação das classes e ajuste do limiar de decisão do classificador.

Com o limiar padrão de classificação, o modelo baseado em EfficientNetB0 manteve acurácia próxima de 67%, porém apresentou baixo recall para a classe maligna. Por esse motivo, foram testados diferentes limiares de decisão, buscando aumentar a sensibilidade do modelo para casos malignos. A Tabela 10 apresenta a comparação dos principais limiares avaliados.

Tabela 10 — Comparação dos limiares de decisão para a classe maligna

| Threshold | Acurácia | Precisão Maligno | Recall Maligno | F1 Maligno |
|-----------|----------|------------------|----------------|------------|
| 0,20      | 0,61     | 0,50             | 0,71           | 0,59       |
| 0,25      | 0,64     | 0,53             | 0,62           | 0,57       |
| 0,30      | 0,64     | 0,54             | 0,50           | 0,52       |
| 0,35      | 0,65     | 0,58             | 0,40           | 0,47       |
| 0,40      | 0,67     | 0,62             | 0,37           | 0,46       |
| 0,45      | 0,67     | 0,67             | 0,33           | 0,44       |
| 0,50      | 0,68     | 0,72             | 0,29           | 0,41       |

Fonte: Autoria própria, 2026.

A análise dos limiares mostrou que o threshold de 0,20 apresentou o melhor F1-score para a classe maligna, com valor de 0,59. Embora a acurácia geral tenha sido reduzida para 61%, o recall da classe maligna aumentou para 0,71, indicando que o modelo passou a identificar uma maior quantidade de casos malignos. A matriz de confusão para esse limiar é apresentada na Tabela 11.

Tabela 11 — Matriz de confusão do classificador EfficientNetB0 com threshold 0,20

|              | Previsto Benigno | Previsto Maligno |
|--------------|------------------|------------------|
| Real Benigno | 127              | 104              |
| Real Maligno | 42               | 105              |

Fonte: Autoria própria, 2026.

O relatório de classificação para o classificador EfficientNetB0 com threshold 0,20 é apresentado na Tabela 12.

Tabela 12 — Relatório de classificação do classificador EfficientNetB0 com threshold 0,20

| Classe                 | Precisão | Recall | F1-score | Suporte |
|------------------------|----------|--------|----------|---------|
| Benigno                | 0,75     | 0,55   | 0,64     | 231     |
| Maligno                | 0,50     | 0,71   | 0,59     | 147     |
| <b>Acurácia</b>        | 0,61     |        |          | 378     |
| <b>Média macro</b>     | 0,63     | 0,63   | 0,61     | 378     |
| <b>Média ponderada</b> | 0,65     | 0,61   | 0,62     | 378     |


Fonte: Autoria própria, 2026.



Os resultados mostram que a escolha do limiar de decisão impacta diretamente o comportamento do classificador. Com limiares mais altos, o modelo apresentou maior precisão para a classe maligna, porém menor recall, deixando de identificar uma quantidade maior de casos malignos. Com o threshold de 0,20, houve aumento do recall da classe maligna, reduzindo a quantidade de falsos negativos. Em contrapartida, ocorreu aumento dos falsos positivos, ou seja, mais casos benignos foram classificados como malignos.


Considerando o contexto do câncer de mama, em que falsos negativos são especialmente críticos, optou-se por priorizar a sensibilidade da classe maligna na análise experimental. Assim, embora a acurácia geral do modelo EfficientNetB0 com threshold 0,20 tenha sido menor, esse ajuste permitiu identificar uma maior proporção de casos malignos, o que é relevante em sistemas acadêmicos de apoio à triagem. As Figuras 15, 16 e 17 apresentam, respectivamente, a evolução da acurácia, da função de perda e da AUC durante o treinamento do classificador baseado em Transfer Learning.

Figura 15 — Evolução da acurácia durante o treinamento do classificador




Fonte: Autoria própria, 2026.

Figura 16 — Evolução da função de perda durante o treinamento do classificador



Fonte: Autoria própria, 2026.

Figura 17 — Evolução da AUC durante o treinamento do classificador



Fonte: Autoria própria, 2026.

A Figura 15 mostra a evolução da acurácia do classificador ao longo das épocas. Observa-se que a acurácia de validação se manteve em torno de valores superiores aos obtidos pela CNN inicial, indicando melhora na capacidade de classificação após o uso de Transfer Learning. A Figura 16 apresenta a função de perda, na qual a curva de treinamento diminui ao longo das épocas, enquanto a validação se mantém relativamente estável. Esse comportamento sugere que o modelo aprendeu padrões dos dados sem uma divergência acentuada entre treinamento e validação. A Figura 17 apresenta a evolução

da AUC, indicando capacidade moderada de separação entre as classes benigna e maligna. Em conjunto, os gráficos mostram que o classificador apresentou desempenho superior à CNN inicial, mas ainda limitado, justificando a análise complementar por matriz de confusão e ajuste do limiar de decisão.

## 4.5 Integração da Segmentação com a Classificação

Após o treinamento dos modelos, a aplicação foi integrada para executar as duas etapas em sequência. O fluxo final consiste no envio de uma mamografia, segmentação da região suspeita com U-Net, pós-processamento da máscara, recorte da região segmentada e classificação experimental da lesão como benigna ou maligna. Na etapa de classificação integrada, foi adotado o limiar de decisão de 0,20 para a classe maligna, com o objetivo de priorizar a sensibilidade do modelo para casos malignos. A Figura 18 apresenta a interface final da aplicação integrada.

Figura 18 — Interface final da aplicação integrada, contendo segmentação, recorte da região suspeita e classificação experimental da lesão.

### Resultado da Segmentação

Segmentar e classificar imagem






Imagem original



Máscara bruta da U-Net



Máscara pós-processada



Região suspeita destacada


### Informações da segmentação

**Pixels segmentados:** 1814

**Área segmentada aproximada:** 2.7679% da imagem

**Qualidade da segmentação:** adequada para análise experimental

### Recorte usado para classificação



Região segmentada recortada

### Resultado da classificação experimental

Classe prevista pelo modelo: **BENIGNO**

**Confiança aproximada:** 85.46%

Fonte: Autoria própria, 2026.


A aplicação também foi ajustada para salvar automaticamente os resultados gerados em uma pasta específica. Para cada imagem analisada, são armazenadas a imagem

original, a máscara bruta, a máscara pós-processada, a região destacada, o recorte utilizado na classificação e um arquivo de informações contendo o limiar utilizado, a quantidade de pixels segmentados, a área aproximada da segmentação e a classe prevista pelo modelo.

## 4.6 Limitações Observadas

Durante os testes integrados, foi observado que a qualidade da classificação depende diretamente da qualidade da segmentação. Em um dos casos analisados, uma imagem pertencente à classe maligna foi classificada como benigna. Nesse exemplo, a U-Net segmentou apenas 99 pixels, correspondendo a aproximadamente 0,1511% da imagem. Como a área segmentada foi muito pequena, o recorte enviado ao classificador provavelmente não representava adequadamente a lesão principal.

Figura 19 — Exemplo de limitação da aplicação integrada, em que uma imagem maligna foi classificada como benigna devido à segmentação reduzida da região suspeita.



Fonte: Autoria própria, 2026.

Esse resultado evidencia uma limitação importante da abordagem integrada: quando a segmentação falha ou identifica uma região muito pequena, a classificação também pode ser prejudicada. Para tornar a aplicação mais transparente, foi incluído

um aviso na interface quando a área segmentada é considerada pequena, indicando que a classificação pode não ser confiável.

Outra limitação observada está relacionada ao ajuste do limiar de decisão do classificador. A redução do threshold para 0,20 aumentou o recall da classe maligna, permitindo identificar mais casos malignos. Entretanto, esse ajuste também elevou o número de falsos positivos, fazendo com que mais casos benignos fossem classificados como malignos. Esse comportamento evidencia o compromisso entre sensibilidade e precisão, comum em problemas de classificação binária aplicados à área da saúde.

De modo geral, os resultados mostram que a U-Net conseguiu realizar uma segmentação inicial das regiões suspeitas em mamografias, principalmente após a correção do pareamento entre imagens e máscaras e a aplicação do pós-processamento. A etapa de classificação também apresentou evolução após o uso de Transfer Learning, deixando de classificar todas as amostras como benignas e passando a reconhecer casos das duas classes.

Apesar disso, o sistema ainda apresenta limitações. A segmentação nem sempre localiza corretamente a lesão, especialmente em casos de regiões pequenas ou de baixo contraste. A classificação, por sua vez, ainda apresenta falsos positivos e falsos negativos, com desempenho dependente do limiar de decisão adotado. Portanto, a aplicação desenvolvida deve ser compreendida como uma ferramenta acadêmica e experimental, não sendo adequada para uso clínico ou diagnóstico médico.

Como trabalhos futuros, recomenda-se ampliar o conjunto de dados utilizado, testar arquiteturas mais robustas de segmentação, aplicar técnicas mais avançadas de balanceamento de classes, avaliar separadamente massas e calcificações e comparar diferentes modelos de classificação. Também seria interessante utilizar validação cruzada e realizar uma análise mais detalhada dos casos em que o modelo apresenta erros.

Portanto, os resultados obtidos indicam que o uso de Redes Neurais Convolucionais, especialmente a U-Net para segmentação e modelos baseados em Transfer Learning para classificação, pode contribuir para o desenvolvimento de ferramentas acadêmicas de apoio à análise de mamografias. No entanto, os resultados também reforçam a necessidade de melhorias nos modelos, validação rigorosa e acompanhamento por especialistas antes de qualquer aplicação em contexto real de saúde.

## 5 Conclusão

Este trabalho teve como objetivo desenvolver uma aplicação em Python para segmentação e classificação experimental de lesões mamográficas, utilizando Redes Neurais Convolucionais aplicadas a imagens da base CBIS-DDSM. Ao longo do desenvolvimento, foram implementadas duas etapas principais: a segmentação de regiões suspeitas por meio de uma arquitetura U-Net e a classificação das lesões em benignas ou malignas utilizando modelos baseados em Transfer Learning.

Durante a etapa de segmentação, foi possível observar que a organização correta dos dados teve influência direta no desempenho do modelo. Inicialmente, o uso das imagens recortadas associado às máscaras ROI gerou resultados insatisfatórios, com máscaras praticamente vazias e métricas próximas de zero. Após a correção do pareamento entre a mamografia completa e a respectiva máscara, a U-Net passou a identificar regiões suspeitas nas imagens, ainda que com limitações. O melhor resultado obtido apresentou Dice Coefficient de validação igual a 0,2459 e IoU de validação igual a 0,1453. Esses valores indicam que a segmentação ainda pode ser aprimorada, mas demonstram que o modelo conseguiu aprender parte dos padrões visuais presentes nas regiões de interesse.

A aplicação do pós-processamento também se mostrou importante para tornar os resultados mais compreensíveis visualmente. A remoção de ruídos, o preenchimento de falhas e o destaque da região segmentada sobre a mamografia facilitaram a interpretação da saída gerada pela U-Net. Dessa forma, mesmo com métricas ainda modestas, foi possível construir uma interface funcional capaz de apresentar a imagem original, a máscara prevista, a máscara refinada e a região suspeita destacada.

Na etapa de classificação, os primeiros resultados evidenciaram uma dificuldade comum em problemas médicos: a tendência do modelo em favorecer uma das classes. Embora a distribuição entre benigno e maligno não fosse extremamente desbalanceada, a CNN inicial apresentou comportamento enviesado para a classe benigna, classificando todas as amostras de validação nessa classe, o que mostrou que a acurácia, sozinha, não era suficiente para avaliar o desempenho. Com o uso de Transfer Learning, inicialmente com MobileNetV2 e posteriormente com EfficientNetB0, o modelo passou a reconhecer casos das duas classes. O ajuste do limiar de decisão para 0,20 aumentou o recall da classe maligna para 0,71, priorizando a identificação de casos malignos. Em contrapartida, houve aumento dos falsos positivos e redução da acurácia geral, o que reforça o compromisso existente entre sensibilidade e precisão.

A integração entre segmentação e classificação permitiu criar uma aplicação completa, capaz de receber uma imagem de mamografia, segmentar uma região suspeita, recortar essa região e gerar uma classificação experimental. Entretanto, os testes mostraram que a classificação depende diretamente da qualidade da segmentação. Quando a U-Net identifica uma região muito pequena ou incorreta, o classificador pode receber um

recorte pouco representativo da lesão, prejudicando a predição final. Esse comportamento foi observado em casos nos quais imagens malignas foram classificadas como benignas, evidenciando uma limitação importante da abordagem integrada.

Apesar das limitações, o desenvolvimento do projeto permitiu demonstrar, de forma prática, como Redes Neurais Convolucionais podem ser aplicadas à análise de mamografias. O sistema desenvolvido não tem finalidade diagnóstica e não substitui a avaliação médica, mas representa uma ferramenta acadêmica de apoio ao estudo de técnicas de segmentação e classificação em imagens médicas. Os resultados obtidos mostram que o uso de U-Net, pós-processamento e modelos baseados em Transfer Learning pode contribuir para a construção de sistemas computacionais voltados à análise de lesões mamográficas.

Como perspectivas para trabalhos futuros, recomenda-se a expansão do conjunto de dados e a investigação de arquiteturas de segmentação mais robustas, aliadas a técnicas rigorosas de balanceamento de classes e validação cruzada. É pertinente, ainda, explorar a implementação desses modelos em paradigmas de Edge Computing, aproveitando a eficiência de arquiteturas como a MobileNetV2 para viabilizar o processamento local e de baixa latência diretamente em dispositivos médicos, reduzindo a dependência de infraestruturas de nuvem. Adicionalmente, sugere-se aprimorar o fluxo de classificação para mitigar a dependência crítica em relação à acurácia da segmentação prévia, além de promover testes assistidos por especialistas da área da saúde, visando aproximar a ferramenta de um cenário operacional robusto de auxílio à análise mamográfica.

Conclui-se que os objetivos propostos foram satisfeitos, consolidando-se na entrega de uma aplicação funcional em Python para a segmentação e classificação experimental de lesões. Embora os resultados obtidos ainda possuam caráter estritamente acadêmico e não atendam aos requisitos para uso clínico imediato, o estudo ratifica o potencial das Redes Neurais Convolucionais na automatização e suporte ao processamento de imagens médicas. O trabalho cumpre seu papel ao sistematizar o conhecimento técnico-experimental na área, estabelecendo uma base inicial que abre caminho para o desenvolvimento de sistemas computacionais de apoio à análise mamográfica mais precisos, robustos e passíveis de validação futura com especialistas.

## Referências

- AFFONSO, Emmanuel T. F. *et al.* Uso de Redes Neurais Multilayer Perceptron (MLP) em Sistema de Bloqueio de Websites Baseado em Conteúdo. **Mecânica Computacional**, v. 29, n. 93, p. 9075–9090, 2010.
- AMBRÓSIO, Paulo Eduardo. **Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais pulmonares**. 2002. Tese (Doutorado) – Universidade de São Paulo, São Paulo.
- BACCOUCHE, Asma; GARCIA-ZAPIRAIN, Begonya; CASTILLO OLEA, Cesar *et al.* Connected-UNets: a deep learning architecture for breast mass segmentation. **NPJ Breast Cancer**, v. 7, n. 151, 2021. DOI: 10.1038/s41523-021-00358-x.
- BACCOUCHE, Asma; GARCIA-ZAPIRAIN, Begonya; ELMAGHRABY, Adel S. An integrated framework for breast mass classification and diagnosis using stacked ensemble of residual neural networks. **Scientific Reports**, v. 12, n. 12259, 2022. DOI: 10.1038/s41598-022-15632-6.
- BILIMORIA, Malcolm M.; MORROW, Monica. The woman at increased risk for breast cancer: evaluation and management strategies. **CA: A Cancer Journal for Clinicians**, v. 45, n. 5, p. 263–278, 1995.
- BORGHESAN, Deise Helena Pelloso *et al.* Auto-exame das mamas: conhecimento e prática entre profissionais da área da saúde de uma instituição pública. **Acta Scientiarum. Health Sciences**, v. 25, n. 1, p. 103–113, 2003.
- CHALA, Luciano Fernandes; BARROS, Nestor de. Avaliação das mamas com métodos de imagem. **Radiologia Brasileira**, v. 40, p. 4–6, 2007.
- COSTA, Francisca Marta de Lima. **Ações de detecção precoce do câncer de mama realizadas por profissionais da estratégia saúde da família**. 2009. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Norte, Natal.
- DICE, Lee R. Measures of the Amount of Ecologic Association Between Species. **Ecology**, v. 26, n. 3, p. 297–302, 1945.
- DOMINGOS, Adib Cecilio Prado. **Redes Neurais Convolucionais para detecção de câncer de mama utilizando regiões de interesse de imagens infravermelhas**. 2021. f. 32. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Universidade Federal de Uberlândia, Uberlândia. Disponível em: <https://repositorio.ufu.br/handle/123456789/33864>. Acesso em: 25 mar. 2026.



DUARTE, D. L. **ACR BI-RADS: sistema de laudos e registro de dados de imagem da mama**: atlas de diagnóstico por imagem da mama. São Paulo: Colégio Brasileiro de Radiologia, 2005. v. 1, p. 574.

ELPÍDIO, Fátima Gisele Gomes. **Sistema de auxílio na avaliação de calcificações mamárias por processamento digital de imagens e inteligência artificial**. 2012. Dissertação (Mestrado em Engenharia Biomédica) – Universidade de Brasília, Brasília. Disponível em: [https://repositorio2.unb.br/browse?type=author&value=Elp%C3%ADdio%2C+F%C3%A1tima+Gisele+Gomes&value\\_lang=pt\\_BR](https://repositorio2.unb.br/browse?type=author&value=Elp%C3%ADdio%2C+F%C3%A1tima+Gisele+Gomes&value_lang=pt_BR). Acesso em: 25 mar. 2026.

FAWCETT, Tom. An Introduction to ROC Analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, 2006.

GONDIM, E. M. D. S. Importância da punção aspirativa por agulha fina no diagnóstico precoce de carcinoma mamário. **Gestão & Produção**, 2013.

GONZALEZ, Rafael C.; WOODS, Richard E. **Digital Image Processing**. 4. ed. [S. l.]: Pearson, 2018.

HAYKIN, Simon. **Redes neurais**: princípios e prática. Porto Alegre: Bookman, 2001.

INSTITUTO NACIONAL DE CÂNCER JOSÉ ALENCAR GOMES DA SILVA. **Deteção precoce do câncer de mama**. 2022. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-do-cancer-de-mama/acoes/deteccao-precoce>. Acesso em: 2 dez. 2025.

INSTITUTO NACIONAL DE CÂNCER JOSÉ ALENCAR GOMES DA SILVA. **Incidência do câncer de mama no Brasil**. [S. l.: s. n.], 2022. Acesso em: 30 jun. 2026. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-do-cancer-de-mama/dados-e-numeros/incidencia>.

JACCARD, Paul. The Distribution of the Flora in the Alpine Zone. **New Phytologist**, v. 11, n. 2, p. 37–50, 1912.

LECUN, Yann *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. DOI: 10.1109/5.726791.

LEE, Rebecca Sawyer *et al.* A curated mammography data set for use in computer-aided detection and diagnosis research. **Scientific Data**, Nature Publishing Group, v. 4, p. 170177, 2017. DOI: 10.1038/sdata.2017.177. Disponível em: <https://www.nature.com/articles/sdata2017177>. Acesso em: 2 dez. 2025.

MARTINS, João Paulo Virgílio Marinho. **EIR: sistema inteligente para detecção e classificação de calcificações em mamografias**. 2016. f. 109. Dissertação (Mestrado em Engenharia Biomédica) – Universidade de Brasília, Brasília. Disponível em: <http://repositorio.unb.br/handle/10482/20466>. Acesso em: 5 abr. 2026.

MINISTÉRIO DA SAÚDE. **Ministério da Saúde e INCA apresentam publicação com dados atualizados sobre câncer de mama no Brasil**. [S. l.: s. n.], 2025. Acesso em: 30 jun. 2026. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/noticias/2025/outubro/ministerio-da-saude-e-inca-apresentam-publicacao-com-dados-atualizados-sobre-cancer-de-mama-no-brasil>.

PAN, Sinno Jialin; YANG, Qiang. A Survey on Transfer Learning. **IEEE Transactions on Knowledge and Data Engineering**, v. 22, n. 10, p. 1345–1359, 2010. DOI: 10.1109/TKDE.2009.191.

PERELMUTER, Guy *et al.* Reconhecimento de imagens bidimensionais utilizando Redes Neurais Artificiais. *In*: ANAIS do VIII SIBGRAPI. [S. l.: s. n.], 1995. p. 197–203.

RESENDE, Lúcio Márcio Perri de *et al.* Avaliação de microcalcificações mamárias de acordo com as classificações do Breast Imaging Reporting and Data System (BI-RADS™) e de Le Gal. **Revista Brasileira de Ginecologia e Obstetrícia**, v. 30, p. 75–79, 2008.

RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. U-Net: Convolutional Networks for Biomedical Image Segmentation. *In*: MEDICAL Image Computing and Computer-Assisted Intervention – MICCAI 2015. [S. l.]: Springer, 2015. p. 234–241. DOI: 10.1007/978-3-319-24574-4\_28. Disponível em: <https://arxiv.org/abs/1505.04597>. Acesso em: 9 dez. 2025.

SANDLER, Mark *et al.* MobileNetV2: Inverted Residuals and Linear Bottlenecks. *In*: PROCEEDINGS of the IEEE Conference on Computer Vision and Pattern Recognition. [S. l.: s. n.], 2018. p. 4510–4520. DOI: 10.1109/CVPR.2018.00474.

SOUZA, Fabiano Hahn. **Mamografia digital em comparação com mamografia convencional no rastreamento de câncer de mama no Brasil: revisão sistemática, custo da doença e análise de custo-efetividade no Sistema Único de Saúde**. 2012. f. 212. Tese (Doutorado em Epidemiologia) – Universidade Federal do Rio Grande do Sul, Porto Alegre. Disponível em: <https://lume.ufrgs.br/handle/10183/76211>. Acesso em: 5 abr. 2026.

TAN, Mingxing; LE, Quoc V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *In*: PROCEEDINGS of the 36th International Conference on Machine Learning. [S. l.]: PMLR, 2019. v. 97. (Proceedings of Machine Learning Research), p. 6105–6114. Disponível em: <https://proceedings.mlr.press/v97/tan19a.html>. Acesso em: 20 out. 2025.

# APÊNDICE A — Estrutura da aplicação

Este apêndice apresenta informações complementares sobre a organização técnica da aplicação desenvolvida para segmentação e classificação experimental de lesões mamográficas.

## A.1 Organização do repositório

O projeto foi organizado em arquivos, modelos treinados e diretórios responsáveis por diferentes etapas do processamento. A Tabela 13 apresenta uma ficha dos principais artefatos do repositório, indicando a função de cada componente no fluxo geral da aplicação.

Tabela 13 — Ficha dos artefatos que compõem o repositório da aplicação

| Item | Artefato              | Nome do arquivo            | Descrição                                                                                                                                                                                                                                             | Código     |
|------|-----------------------|----------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| 1    | Script principal      | <code>app.py</code>        | Script principal da aplicação desenvolvida em Streamlit. Responsável por carregar a imagem enviada pelo usuário, executar a segmentação com U-Net, aplicar o pós-processamento, realizar a classificação experimental e salvar os resultados gerados. | 532 linhas |
| 2    | Script de treinamento | <code>train_unet.py</code> | Script utilizado para o treinamento do modelo de segmentação U-Net, incluindo leitura das imagens e máscaras, pré-processamento, definição da arquitetura, função de perda, métricas e salvamento do modelo treinado.                                 | 404 linhas |

| Item | Artefato              | Nome do arquivo                        | Descrição                                                                                                                                                                                                                                    | Código     |
|------|-----------------------|----------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| 3    | Script de treinamento | <code>train_classifier.py</code>       | Script utilizado para o treinamento dos modelos de classificação benigno/maligno, incluindo organização dos dados, uso de Transfer Learning, aplicação de aumento de dados, ponderação de classes e avaliação por métricas de classificação. | 312 linhas |
| 4    | Modelo treinado       | <code>model_unet.keras</code>          | Arquivo contendo o modelo U-Net treinado para segmentação experimental de regiões suspeitas em mamografias.                                                                                                                                  | —          |
| 5    | Modelo treinado       | <code>model_classifier.keras</code>    | Arquivo contendo o modelo classificador treinado para classificação experimental das lesões em benignas ou malignas.                                                                                                                         | —          |
| 6    | Diretório de dados    | <code>dataset_seg/</code>              | Diretório contendo as imagens mamográficas completas e as respectivas máscaras ROI utilizadas na etapa de segmentação.                                                                                                                       | —          |
| 7    | Diretório de dados    | <code>dataset_seg/images/train/</code> | Diretório contendo as imagens mamográficas completas utilizadas no treinamento da U-Net.                                                                                                                                                     | —          |
| 8    | Diretório de dados    | <code>dataset_seg/images/val/</code>   | Diretório contendo as imagens mamográficas completas utilizadas na validação da U-Net.                                                                                                                                                       | —          |
| 9    | Diretório de dados    | <code>dataset_seg/masks/train/</code>  | Diretório contendo as máscaras ROI correspondentes às imagens de treinamento da U-Net.                                                                                                                                                       | —          |

| Item | Artefato                | Nome do arquivo                      | Descrição                                                                                                                                                                                                                    | Código   |
|------|-------------------------|--------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------|
| 10   | Diretório de dados      | dataset_seg/masks/val/               | Diretório contendo as máscaras ROI correspondentes às imagens de validação da U-Net.                                                                                                                                         | —        |
| 11   | Diretório de dados      | dataset_classification/              | Diretório contendo as imagens recortadas das lesões organizadas em classes para treinamento e validação do classificador.                                                                                                    | —        |
| 12   | Diretório de dados      | dataset_classification/train/benign/ | Diretório contendo imagens de lesões benignas utilizadas no treinamento do classificador.                                                                                                                                    | —        |
| 13   | Diretório de dados      | dataset_classification/train/malign/ | Diretório contendo imagens de lesões malignas utilizadas no treinamento do classificador.                                                                                                                                    | —        |
| 14   | Diretório de dados      | dataset_classification/val/benign/   | Diretório contendo imagens de lesões benignas utilizadas na validação do classificador.                                                                                                                                      | —        |
| 15   | Diretório de dados      | dataset_classification/val/malign/   | Diretório contendo imagens de lesões malignas utilizadas na validação do classificador.                                                                                                                                      | —        |
| 16   | Diretório de saída      | resultados_tcc/                      | Diretório em que são salvos automaticamente os resultados gerados pela aplicação, incluindo imagem original, máscara bruta, máscara pós-processada, região destacada, recorte da lesão e arquivo de informações da execução. | —        |
| 17   | Arquivo de dependências | requirements.txt                     | Arquivo contendo as bibliotecas necessárias para instalação e execução da aplicação.                                                                                                                                         | 8 linhas |

| Item | Artefato     | Nome do arquivo | Descrição                                                                                                                                           | Código     |
|------|--------------|-----------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| 18   | Documentação | README.md       | Arquivo de documentação do projeto, contendo informações gerais sobre o repositório, dependências, instruções de execução e descrição da aplicação. | 112 linhas |

Fonte: Autoria própria, 2026.

## A.2 Repositório

O código-fonte da aplicação está disponível em repositório privado no GitHub, no endereço apresentado em: <https://github.com/jma-ju/-Segmentacao-e-classificacao-experimental-de-lesoes-mamograficas>.

## A.3 Instruções básicas de execução

Para executar a aplicação, recomenda-se criar um ambiente virtual Python e instalar as dependências listadas no arquivo `requirements.txt`. Após a configuração do ambiente e a presença dos modelos treinados no diretório do projeto, a aplicação pode ser iniciada pelo comando:

```
streamlit run app.py
```

Após a execução, a interface permite o envio de imagens mamográficas em formato JPG, JPEG ou PNG, exibindo os resultados da segmentação, do pós-processamento, da classificação experimental e o salvamento automático dos arquivos gerados.

## A.4 Trechos principais do código

Para complementar a documentação da aplicação, esta seção apresenta trechos representativos do código utilizado no carregamento dos modelos, no processamento da imagem enviada pelo usuário e na execução da classificação experimental. Os códigos completos encontram-se disponíveis no repositório do projeto.

```

1  from tensorflow.keras.models import load_model
2
3  model_unet = load_model("model_unet.keras", compile=False)
4  model_classifier = load_model("model_classifier.keras", compile=False)

```

Listing A.1 — Carregamento dos modelos treinados

```
1  imagem_entrada = preprocessar_imagem(imagem)
2  mascara_prevista = model_unet.predict(imagem_entrada)[0, :, :, 0]
3  mascara_binaria = mascara_prevista > limiar_segmentacao
```

Listing A.2 — Predição da máscara pela U-Net

```
1  probabilidade_maligno = model_classifier.predict(recorte)[0][0]
2
3  if probabilidade_maligno >= 0.20:
4      classe_prevista = "MALIGNO"
5  else:
6      classe_prevista = "BENIGNO"
```

Listing A.3 — Classificação experimental da região segmentada